

---

**UNIVERSIDAD POLITÉCNICA DE VALENCIA**

**Departamento de Proyectos de Ingeniería**

---



**Optimización de la distribución en planta de instalaciones  
industriales mediante algoritmos genéticos.  
Aportación al control de la geometría de las actividades.**

**TESIS DOCTORAL**

**PRESENTADA POR:**

**D. José Antonio Diego-Más**

**DIRIGIDA POR:**

**Dr.D. Vicente Cloquell Ballester**

**Dra. D<sup>a</sup>. M<sup>a</sup> Cristina Santamarina Siurana**

**VALENCIA, Enero 2006**



---

## **AGRADECIMIENTOS**

Valga el presente párrafo para agradecer, en lo que es justo, las diversas formas de colaboración de mis compañeros del Departamento de Proyectos de Ingeniería de la Universidad Politécnica de Valencia.  
Sin su contribución esta tesis hubiera sido otra.

---

Entra y mira,  
verás que no es el Caos lo que rige las cosas de este mundo;  
es, si acaso, la Complejidad.

Entra y escucha,  
entre el estruendo distinguirás un leve ritmo;  
es bálsamo para el corazón de los Escépticos.

A Sabina, por hacer girar el mundo  
a Aitana, por hacerlo girar en el sentido adecuado  
a Antonio, a Julia y a Ana, ellos hicieron el mundo

## RESUMEN

Las actividades industriales desarrolladas en entornos competitivos se rigen cada vez más por los condicionantes de un mercado exigente y selectivo, en el que la eficiencia en el desempeño de todas las facetas del proceso productivo se hace condición necesaria para la subsistencia de la empresa. Uno de estos aspectos que deben diseñarse con esmero, dado que repercute directamente en los costes de producción, es la distribución de las diferentes actividades del proceso productivo en la planta.

Desde la década de los 50 han surgido multitud de procedimientos de generación y evaluación de layouts, diferenciados fundamentalmente por la modelización del problema, el número de criterios contemplados, y las técnicas de resolución empleadas. Entre las condiciones que debe cumplir una distribución para poder implantarse sin un gran reajuste está que el área asignada a las actividades observe determinadas restricciones; fundamentalmente que el tamaño de dicha área sea suficiente para albergar la actividad, y que la geometría de la misma permita su normal desempeño. En el presente trabajo, y tras un exhaustivo análisis del estado de la cuestión, se propondrá un método para la resolución del problema de la distribución en planta que considera múltiples criterios en la evaluación de la calidad de las soluciones, y que resulta especialmente eficaz en el respeto de las restricciones geométricas sin perder eficiencia en la consideración del resto de los criterios. Se plantea la exploración del espacio de soluciones en dos fases: una de acotación de la búsqueda y otra de búsqueda exhaustiva, mediante sendos algoritmos genéticos que incorporan procedimientos de guiado de la exploración que en la bibliografía han demostrado su eficacia.

Para lograrlo se ha llevado a cabo un análisis del estado del arte de los modelos y métodos de resolución del problema de distribución en planta, de los diferentes enfoques y planteamientos, y de los resultados que se obtienen con cada uno de ellos. Se ha estudiado el funcionamiento y el estado de las técnicas heurísticas y metaheurísticas empleadas en la resolución del problema. Se ha analizado la teoría en la que se asientan los algoritmos evolutivos, y se han empleado dichos conocimientos para lograr una correcta y eficaz aplicación al problema en cuestión. Se ha definido un indicador de la calidad de los resultados obtenidos, fundamentalmente desde el punto de vista geométrico, que permite salvar la incertidumbre existente en la primera fase del proceso de búsqueda de soluciones mediante el procedimiento que se plantea. Además, se ha desarrollado una aplicación informática que implementa el algoritmo propuesto, y que permite automatizar el proceso de resolución de problemas de distribución aprovechando el potencial de cálculo de una red de ordenadores.

En definitiva, en este trabajo se ha desarrollado un método eficiente que permite obtener distribuciones en planta de actividades industriales de elevada calidad bajo múltiples criterios, estableciendo como fundamental e irrenunciable, que el área asignada a las diferentes actividades cumplan estrictamente las restricciones geométricas impuestas.

## RESUM

Les activitats industrials desenvolupades en entorns competitius es regeixen cada vegada més pels condicionaments d'un mercat exigent i selectiu, en el qual l'eficiència en l'acompliment de totes les facetes del procés productiu es fa condició necessària per a la subsistència de l'empresa. Un d'aquests aspectes que han de dissenyar-se amb cura és la distribució de les diferents activitats del procés productiu en la planta, atès que repercuteix directament en els costos de producció.

Des de la dècada dels 50 han sorgit multitud de procediments de generació i avaluació de layouts, diferenciats fonamentalment per la modelització del problema, el nombre de criteris contemplats, i les tècniques de resolució emprades. Entre les condicions que ha de complir una distribució per a poder implantar-se sense un gran reajustament, està que l'àrea assignada a les activitats observi determinades restriccions; fonamentalment que la grandària d'aquesta àrea sigui suficient per a albergar l'activitat, i que la geometria de la mateixa permeti el seu normal acompliment. En el present treball, i després d'una exhaustiva anàlisi de l'estat de la qüestió, es proposarà un mètode per a la resolució del problema de la distribució en planta que considera múltiples criteris en l'avaluació de la qualitat de les solucions, i que resulta especialment eficaç en el respecte de les restriccions geomètriques sense perdre eficiència en la consideració de la resta dels criteris. Es planteja l'exploració de l'espai de solucions en dues fases: una d'acotament de la recerca i altra de recerca exhaustiva, mitjançant sengles algorismes genètics que incorporen procediments de guiat de l'exploració que en la bibliografia han demostrat la seva eficàcia.

Per a assolir-lo s'ha portat a terme una anàlisi de l'estat de l'art dels models i mètodes de resolució del problema de distribució en planta, dels diferents enfocaments i plantejaments, i dels resultats que s'obtenen amb cadascun d'ells. S'ha estudiat el funcionament i l'estat de les tècniques heurístiques i metaheurístiques emprades en la resolució del problema. S'ha analitzat la teoria en la qual s'assenten els algorismes evolutius, i s'han emprat aquests coneixements per a assolir una correcta i eficaç aplicació al problema en qüestió. S'ha definit un indicador de la qualitat dels resultats obtinguts, fonamentalment des del punt de vista geomètric, que permet salvar la incertesa existent en la primera fase del procés de recerca de solucions mitjançant el procediment que es planteja. A més, s'ha desenvolupat una aplicació informàtica que implementa l'algorisme proposat, i que permet automatitzar el procés de resolució de problemes de distribució aprofitant el potencial de càlcul d'una xarxa d'ordinadors.

En definitiva, en aquest treball s'ha desenvolupat un mètode eficient que permet obtenir distribucions en planta d'activitats industrials d'elevada qualitat sota múltiples criteris, establint com fonamental i irrenunciable, que l'àrea assignada a les diferents activitats compleixin estrictament les restriccions geomètriques imposades.

## ABSTRACT

Industrial activities developed within competitive environments are ever more guided by a demanding and selective market, in which the efficiency in all the aspects of the production process becomes a necessary condition for the survival of the business. One of these aspects, and one which must be designed with care, is the distribution of the different activities of the production process within the plant, given its direct repercussion on production costs.

A number of procedures for the generation and evaluation of layouts have emerged since the 1950s. The fundamental differences between these are: the modelling of the problem, the number of criteria being considered, and the solution techniques employed. Within the conditions that a distribution must meet if it is to be implanted without great modification, is that the area assigned to the activities must fulfil certain conditions; it is fundamental that the size of the area be sufficient to accommodate the activity, and that its geometry permit its normal functioning. In the present work, and after an exhaustive analysis of the state of art, a method for the solution of the problem of plant layout is presented. It is a method which considers multiple criteria in the evaluation of the quality of the solutions, and which is especially efficient in the fulfilment of the geometric restrictions without losing efficiency in the consideration of the remaining criteria.

The search for the space of solutions is set out in two phases, one to limit the searching space and another of exhaustive search; each by means of genetic algorithms, which incorporate procedures to guide the exploration which have demonstrated their efficiency/effectiveness throughout the literature.

To achieve this, an analysis of the state of art was undertaken on the models and the methods of solution to the plant layout problem, both on the different approaches adopted and on the results obtained from each of the above. The state and operation of the heuristic and metaheuristic techniques employed in the problem were studied. The theory underlying evolutive algorithms was analysed and the knowledge derived thereof applied to achieve a correct and efficient application to the problem in question. An indicator on the quality of the results obtained was defined, primarily from a geometric point of view to remove the uncertainty existent in the first phase of the solution searching process. Moreover, a computer application was developed to implement the proposed algorithm, and thus enable automation of the solution to distribution problems thereby taking advantage of the calculation potential of a computer network.

In conclusion, the present work has developed an efficient method for the development of high quality plant layouts of industrial activities, whereby it is considered fundamental and inalienable the area assigned to the different activities strictly fulfils the geometric restrictions imposed.





# ÍNDICE

## CAPÍTULO 1

<b>1. OBJETIVOS Y ALCANCE DE LA INVESTIGACIÓN</b>	<b>2</b>
1.1. Introducción	2
1.2. Objetivos de la investigación	3
1.3. Metodología y estructura de los contenidos	4

## CAPÍTULO 2

<b>2. DISTRIBUCIÓN EN PLANTA.</b>	<b>8</b>
2.1. Introducción	8
2.2. Objetivos de la distribución en planta y definiciones del problema	12
2.2.1 Principios de la distribución en planta	15
2.3. La distribución en nueva planta frente a la reordenación de una planta existente	16
2.4. Tipos básicos de distribución en planta de los medios de producción	18
2.4.1 Distribución por posición fija	20
2.4.2 Distribución por proceso, por funciones, por secciones o por talleres.	21
2.4.3 Distribución por producto, en cadena o en serie	21
2.4.4 Células de trabajo o células de fabricación flexible	22
2.4.5 Tipos básicos de distribución y características fundamentales	23
2.5. La distribución en planta como problema de diseño	23
2.5.1 Primeras aproximaciones metodológicas al problema de la distribución en planta	27
2.5.1.1 El <i>método de los pasos</i> o etapas básicas de Immer	28
2.5.1.2 El <i>sequence analysis</i> de Buffa	28
2.5.1.3 Propuestas metodológicas posteriores al SLP	30
2.5.1.3.1 La propuesta de Reed	30
2.5.1.3.2 El " <i>ideal systems approach</i> " de Nadler	30
2.5.1.3.3 La propuesta de Apple	31
2.5.2 El systematic layout planning (SLP) de Muther	32
2.5.2.1 Análisis P-Q	33
2.5.2.2 Análisis del recorrido de los productos	34
2.5.2.3 Análisis de las relaciones entre actividades	35
2.5.2.4 Diagrama relacional de recorridos y/o actividades	35
2.5.2.5 Diagrama relacional de espacios	38
2.6. Medición de la distancia y de la forma	39
2.6.1 Métricas de distancia	40
2.6.2 Medición de la forma	42
2.7. Clasificación de las técnicas para la resolución del problema	44
2.7.1 Clasificación de las técnicas por el modelo espacial empleado para situar las actividades en el dominio de ubicación	45

2.7.1.1 Modelos topológicos	46
2.7.1.1.1 Teoría de grafos	46
2.7.1.2 Modelos geométricos	49
2.7.1.3 Modelos discretos	51
2.7.1.3.1 Curvas de llenado de espacios	53
2.7.1.3.2 El control de la agregación en los modelos discretos	54
2.7.1.4 Modelos continuos	54
2.7.1.4.1 Árboles de corte	55
2.7.1.4.2 Estructuras de bahías flexibles	61
2.7.1.4.3 Space Partitioning Method	62
2.7.1.5 Modelos analíticos	64
2.7.2 Clasificación de los métodos de resolución por la técnica empleada para solucionar el problema	65
2.7.2.1 Métodos óptimos/exactos	66
2.7.2.1.1 Algoritmos branch and bound (ramificación y acotación)	67
2.7.2.1.2 Algoritmos de planos de cortes	67
2.7.2.2 Métodos heurísticos	68
2.7.2.2.1 Métodos constructivos	69
2.7.2.2.2 Métodos de mejora	71
2.7.2.2.3 Métodos híbridos	72
2.7.2.3 Metaheurísticas	72

## CAPÍTULO 3

<b>3. METAHEURÍSTICAS Y REDES NEURONALES PARA LA DISTRIBUCIÓN EN PLANTA DE ACTIVIDADES INDUSTRIALES</b>	<b>74</b>
3.1. Introducción	74
3.2. Recocido Simulado (Simulated Annealing)	75
3.2.1 Definición general	75
3.2.1.1 El algoritmo Metrópolis	76
3.2.1.1.1 La simulación Montecarlo	76
3.2.1.1.2 El método Metropolis	77
3.2.1.2 La propuesta de Kirkpatrick, Gelatt y Vecchi	77
3.2.2 Estructura del algoritmo	78
3.2.2.1 Generación de la solución inicial	80
3.2.2.2 Determinación de la temperatura inicial	81
3.2.2.3 Definición del entorno de una solución	81
3.2.2.4 El criterio de parada (criterio de congelación)	82
3.2.2.5 Condición de equilibrio y esquema de enfriamiento	82
3.2.3 Aplicación del recocido simulado a la distribución en planta	84
3.3. Búsqueda Tabú (Tabu Search)	84
3.3.1 Definición general	84
3.3.2 La lista tabú y los criterios de aspiración	86
3.3.3 Definición del entorno y creación de la lista de candidatos	89

3.3.4 Tipos de memoria; estrategias de intensificación y diversificación	91
3.3.4.1 El proceso de intensificación	92
3.3.4.2 El proceso de diversificación	93
3.3.4.3 Path Relinking y Tunneling	94
3.3.4.4 Oscilación estratégica	95
3.3.4.5 Los algoritmos tabú con umbral	95
3.3.5 Aplicación de la búsqueda tabú a la distribución en planta	96
3.4. Computación evolutiva	96
3.4.1 Introducción	96
3.4.2 Dualidad genotipo / fenotipo	97
3.4.3 Técnicas de computación evolutiva	99
3.4.3.1 Algoritmos genéticos	99
3.4.3.1.1 Programas de evolución	101
3.4.3.2 Estrategias evolutivas	101
3.4.3.3 Programación evolutiva	102
3.4.3.4 Otras técnicas	103
3.5. Colonias de hormigas	104
3.5.1 Aplicación de los algoritmos de hormigas a la distribución en planta	107
3.6. Redes neuronales artificiales	108
3.6.1 Las redes neuronales naturales	108
3.6.1.1 Funcionamiento de una neurona biológica	108
3.6.2 Redes neuronales artificiales	110
3.6.2.1 La neurona artificial	111
3.6.2.2 Topología de las Redes Neuronales	113
3.6.3 Entrenamiento de una red neuronal	114
3.6.4 Tipos de redes neuronales	115
3.6.4.1 El Perceptron	115
3.6.4.2 Adaline	116
3.6.4.3 Backpropagation	116
3.6.4.4 Red de Hopfield	116
3.6.4.5 Otros tipos de redes	116
3.6.5 Aplicación de las redes neuronales al problema de la distribución en planta	117

## CAPÍTULO 4

<b>4. ALGORITMOS GENÉTICOS: FUNCIONAMIENTO Y BASES TEÓRICAS.</b>	<b>120</b>
4.1. Introducción	120
4.2. Terminología y analogías planteadas	122
4.3. Estructura básica de un algoritmo genético	125
4.3.1 Condiciones para una correcta implementación de los algoritmos genéticos	127
4.4. Base teórica de los algoritmos genéticos	127
4.4.1 Concepto de esquema	127
4.4.2 Teorema fundamental de los algoritmos genéticos. Teorema del esquema o teorema de Holland	129

---

4.4.3 El paralelismo implícito de los algoritmos genéticos	133
4.4.4 Limitaciones del algoritmo genético básico y de su base teórica	134
4.5. Codificación de las soluciones	136
4.6. Creación de la población inicial	138
4.7. La función de evaluación y la función de aptitud	138
4.7.1 Desplazamiento y escalado	139
4.7.1.1 El escalado lineal	140
4.7.1.2 El truncado $\sigma$	140
4.7.1.3 El escalado potencial o ley potencial del escalado	141
4.8. Los operadores genéticos	141
4.8.1 El proceso de selección y reemplazo	141
4.8.1.1 Tipos de procesos de selección	142
4.8.1.2 Procesos de reemplazo	145
4.8.1.2.1 Estrategias elitistas	146
4.8.1.3 Algoritmos generacionales y de estado estacionario	147
4.8.1.4 La edad de los individuos	148
4.8.2 Operadores genéticos; efecto de los operadores.	150
4.8.2.1 El operador cruce	152
4.8.2.1.1 Cruce monopunto	152
4.8.2.1.2 Cruce bipunto	152
4.8.2.1.3 Cruce multipunto	153
4.8.2.1.4 Cruce segmentado	153
4.8.2.1.5 Cruce uniforme	153
4.8.2.1.6 Partially matched crossover (PMX) y cruce por orden	154
4.8.2.1.7 Cruce sobre alfabetos de alta cardinalidad	154
4.8.2.1.8 Mecanismos adicionales a los operadores de cruce	155
4.8.2.1.9 Comparaciones de los diferentes tipos de cruce	155
4.8.2.2 El operador mutación	156
4.8.2.2.1 Mutación sobre alfabetos de alta cardinalidad	157
4.8.2.2.2 Mutaciones por intercambio de posición	157
4.8.2.2.3 Mutaciones no uniformes	157
4.8.2.3 El operador inversión	157
4.9. Estrategias frente a los individuos no factibles	159
4.9.1 Descarte o penalización	160
4.9.1.1 Funciones de penalización adaptativas	160
4.9.2 Reparación	161
4.9.3 Codificación cerrada	162
4.10. Parametrización de los algoritmos genéticos	163
4.10.1.1 Meta-algoritmos genéticos para la determinación de parámetros de ejecución	164
4.10.2 Parametrización adaptativa	164
4.11. Hibridación de los algoritmos genéticos	166
4.11.1 Combinación de metaheurísticas en algoritmos híbridos	168

## CAPÍTULO 5

<b>5. ALGORITMOS GENÉTICOS APLICADOS AL PROBLEMA DE LA DISTRIBUCIÓN EN PLANTA</b>	<b>172</b>
5.1. Introducción	172
5.2. Las propuestas de Tam	173
5.2.1 La primera propuesta de Tam	174
5.2.1.1 Determinación del árbol de cortes	174
5.2.1.2 Determinación de la distribución óptima	176
5.2.1.2.1 Operadores genéticos	178
5.2.2 La segunda propuesta de Tam: integración del árbol de cortes en el proceso evolutivo	181
5.3. El método LAYAGEN de Santamarina	183
5.3.1 Introducción	183
5.3.2 La primera fase: optimización del árbol de cortes	184
5.3.2.1 Codificación de los árboles de corte	184
5.3.2.2 Generación de la población inicial de árboles de corte	187
5.3.2.3 Estimación de la capacidad del árbol de cortes para generar distribuciones de mínimo coste relacional	187
5.3.2.3.1 Potencial de adyacencia entre actividades de un árbol de cortes	188
5.3.2.3.2 Potencial del árbol de cortes	192
5.3.2.4 Los operadores genéticos	192
5.3.2.4.1 Selección	192
5.3.2.4.2 Cruce	192
5.3.2.4.3 Mutación	194
5.3.3 La segunda fase: optimización de las distribuciones contenidas en el árbol de cortes	196
5.3.3.1 Codificación de las soluciones y generación de la población inicial	197
5.3.3.2 Medición de la aptitud de los individuos	198
5.3.3.3 Operadores genéticos	199
5.4. La propuesta de Kado, Ross y Corne	201
5.5. Otras propuestas y estudios destacables	202
5.5.1 La propuesta de Al-Hakim	203

## CAPÍTULO 6

<b>6. METODOLOGÍA PROPUESTA</b>	<b>206</b>
6.1. Introducción	206
6.1.1 Técnicas en una fase versus técnicas en dos fases en el control geométrico de las actividades	209
6.1.2 La evaluación de la calidad geométrica del árbol de cortes	212
6.2. Hipótesis planteadas para el desarrollo de la metodología	213
6.3. Potencial geométrico del árbol de cortes	214
6.3.1 Potencial geométrico de un árbol de cortes básico	215
6.3.1.1 Incumplimiento formal de las actividades	217
6.3.1.2 Potencial geométrico del árbol de cortes básico a partir de los incumplimientos	

formales de las actividades	224
6.3.2 Potencial geométrico de un árbol de cortes formado por un árbol básico y una actividad (árbol básico-actividad)	227
6.3.3 Potencial geométrico de un árbol de cortes formado por dos árboles básicos que penden de un nodo (árbol básico-básico)	233
6.3.4 Generalización del cálculo del potencial geométrico a cualquier tipo de árbol de cortes	234
6.4. Definición de una función evaluadora para la primera fase de LAYAGEN G, optimización del árbol de cortes	239
6.4.1 Potencial del árbol de cortes	240
6.5. Estructura general del algoritmo LAYAGEN G	243
6.6. La primera fase de LAYAGEN G (LG1)	244
6.6.1 Codificación de los árboles de cortes	246
6.6.2 Formación de la población inicial de soluciones	251
6.6.3 Evaluación de la adaptación de los individuos de la población al medio	251
6.6.4 Operadores genéticos en LAYAGEN	255
6.6.4.1 Efectos de la selección y el reemplazo en LAYAGEN	255
6.6.4.2 Efectos del cruce en LAYAGEN	256
6.6.4.3 Efectos de la mutación en LAYAGEN	259
6.6.5 Operadores genéticos en LAYAGEN G	260
6.6.5.1 Selección, reemplazo y elitismo	260
6.6.5.1.1 Selección	260
6.6.5.1.2 Reemplazo	262
6.6.5.1.3 La élite	262
6.6.5.2 Cruce	264
6.6.5.3 Mutación	265
6.6.5.3.1 Mutación geométrica	267
6.6.5.3.2 Medición de la convergencia de la población	268
6.6.6 Intensificación de la búsqueda; hibridación del algoritmo	270
6.6.7 Finalización de LG1 y transición a LG2	273
6.7. La segunda fase de LAYAGEN G (LG2)	274
6.7.1 Codificación de las soluciones y generación de la población inicial	276
6.7.2 La función de aptitud	277
6.7.3 Operadores genéticos en LG2	279
6.7.3.1.1 La élite	280
6.7.4 Búsqueda local en LG2; exploración de ratios	281

## CAPÍTULO 7

<b>7. IMPLEMENTACIÓN INFORMÁTICA DE LAYAGEN G</b>	<b>286</b>
7.1. Introducción	286
7.2. Introducción de datos	286
7.3. Ejecución de LG1	287
7.4. Ejecución de LG2	290

7.5. Automatización del proceso de experimentación	291
7.6. Ejecución distribuida en una red de ordenadores	292

## CAPÍTULO 8

<b>8. VALIDACIÓN EXPERIMENTAL DE LA METODOLOGÍA PROPUESTA</b>	<b>296</b>
8.1. Introducción	296
8.2. Parametrización del algoritmo	297
8.2.1 Parametrización de LG1	301
8.2.1.1 Descripción de los experimentos	301
8.2.1.2 Exposición y análisis de los resultados de los experimentos	302
8.2.2 Parametrización de LG2	305
8.2.2.1 Descripción de los experimentos	305
8.2.2.2 Exposición y análisis de los resultados de los experimentos	307
8.3. Análisis de los tiempos de ejecución de LG1	315
8.3.1 Introducción	315
8.3.2 Descripción de los experimentos	317
8.3.3 Resultado de los experimentos	317
8.4. Resolución de problemas de la bibliografía	321
8.4.1 Introducción	321
8.4.2 Descripción de los problemas a resolver	321
8.4.2.1 El problema de Francis y White	321
8.4.2.2 El problema de Armour y Buffa	322
8.4.2.3 El problema de Tam de 30 actividades	323
8.4.3 Medición de la complejidad de los problemas	325
8.4.4 Resultados de los problemas escogidos y comparación con soluciones alcanzadas mediante otros métodos	328
8.4.4.1 El problema de Francis y White	328
8.4.4.2 El problema de Armour y Buffa	332
8.4.4.3 El problema de Tam de 30 actividades	340
8.5. Resolución de un problema con requerimientos formales diversos (E3)	344
8.5.1 El problema planteado	344
8.5.1.1 Medición de la complejidad del problema	347
8.5.2 Descripción del experimento	348
8.5.3 Exposición y análisis de los resultados de los experimentos	349

## CAPÍTULO 9

<b>9. CONCLUSIONES Y TRABAJOS FUTUROS</b>	<b>354</b>
9.1. Conclusiones	354
9.2. Trabajos futuros	357

**CAPÍTULO 10**

<b>10. RESULTADOS COMPLETOS DE LOS EXPERIMENTOS REALIZADOS</b>	<b>360</b>
10.1. EXPERIMENTOS DE PARAMETRIZACIÓN (E1)	360
10.1.1 Resultados del experimento E1-1	360
10.1.2 Resultados del experimento E1-2	361
10.1.3 Resultados del experimento E1-3	362
10.1.4 Resultados del experimento E1-4	363
10.1.5 Resultados del experimento E1-5	364
10.1.6 Resultados del experimento E1-6	365
10.1.7 Resultados del experimento E1-7	366
10.2. RESULTADOS DE LOS EXPERIMENTOS DE PARAMETRIZACIÓN (E2)	367
10.2.1 Resultados del experimento E2-1	367
10.2.2 Resultados del experimento E2-2	368
10.2.3 Resultados del experimento E2-3	369
10.2.4 Resultados del experimento E2-4	370
10.2.5 Resultados del experimento E2-5	371
10.2.6 Resultados del experimento E2-6	372
10.2.7 Resultados del experimento E2-7	373
10.2.8 Resultados del experimento E2-8	374
10.2.9 Resultados del experimento E2-9	375
10.2.10 Resultados del experimento E2-10	376
10.2.11 Resultados del experimento E2-11	377
10.2.12 Resultados del experimento E2-12	378
10.2.13 Resultados del experimento E2-13	379
10.2.14 Resultados del experimento E2-14	380
10.3. RESULTADOS DEL EXPERIMENTO (E3)	381
10.3.1 Resultados obtenidos en LG1	381
10.3.2 Resultados obtenidos en LG2	382
10.3.2.1 Ejecución 1	382
10.3.2.2 Ejecución 2	383
10.3.2.3 Ejecución 3	384
10.3.2.4 Ejecución 4	385
10.3.2.5 Ejecución 5	386
10.3.2.6 Ejecución 6	387
10.3.2.7 Ejecución 7	388
10.3.2.8 Ejecución 8	389
10.3.2.9 Ejecución 9	390
10.3.2.10 Ejecución 10	391

**CAPÍTULO 11**

<b>11. BIBLIOGRAFÍA</b>	<b>394</b>
-------------------------	------------



## ÍNDICE DE FIGURAS

### CAPÍTULO 2

Figura 2.1	Fases de la planificación de una actividad industrial.	9
Figura 2.2	Sistema planta industrial y subsistemas que lo conforman.	10
Figura 2.3	Tipos de problema de distribución y causas más frecuentes. Adaptado y ampliado de [Moore, 62]	18
Figura 2.4	Distribución por posición fija: ensamblaje de un avión Airbus A340/600 en la planta de Airbus en Toulouse (Francia).	20
Figura 2.5	Distribución en planta por proceso.	21
Figura 2.6	Distribución en planta por producto.	22
Figura 2.7	Aplicación del proceso de diseño en ingeniería a la distribución en planta.	25
Figura 2.8	Aproximación secuencial al proceso de diseño de la planta industrial.	26
Figura 2.9	Aproximación integrada al proceso de diseño de la planta industrial.	27
Figura 2.10	Diagrama esquemático ideal en el Sequence Analysis de Buffa.	29
Figura 2.11	Diagrama de bloques en el Sequence Analysis de Buffa.	29
Figura 2.12	Esquema del "ideal systems approach" de Nadler.	31
Figura 2.13	Esquema del systematic layout planning [Muther, 68].	33
Figura 2.14	Gráficas P-Q habituales de cada tipo de distribución en planta.	34
Figura 2.15	Tabla relacional de actividades.	36
Figura 2.16	Diagrama relacional de actividades (a) y recorridos (b).	37
Figura 2.17	Diagrama relacional de espacios con indicación del área requerida por cada actividad.	39
Figura 2.18	Disposiciones que minimizan las distancia entre centroides de las áreas de las actividades.	40
Figura 2.19	Métricas de distancia entre actividades. Ampliado de [Shebanie, 02].	41
Figura 2.20	Cálculo de la compacidad de actividades	43
Figura 2.21	Clasificación de los modelos espaciales empleados por las técnicas de resolución del problema de distribución en planta.	46
Figura 2.22	Diagrama topológico de actividades.	46
Figura 2.23	Generación de un grafo planar ponderado maximal a partir de un diagrama relacional. Adaptado de [Santamarina, 95].	47
Figura 2.24	Construcción de un grafo dual e introducción de una actividad exterior ficticia). Adaptado de [Santamarina, 95].	48
Figura 2.25	Transformación del grafo dual en un layout de bloques. Adaptado de [Santamarina, 95]	49
Figura 2.26	Modelos geométricos (a) unidimensionales, (b) bidimensionales, (c) multiplanta y (d) tridimensionales.	49
Figura 2.27	Ejemplo de solución obtenida mediante técnicas discretas.	52
Figura 2.28	Curvas de llenado de espacios e intercambio de actividades en la secuencia de actividades.	53

Figura 2.29	Solución obtenida mediante técnicas de corte.	54
Figura 2.30	Actividad de geometría flexible.	55
Figura 2.31	Construcción de una distribución por cortes recursivos del dominio.	55
Figura 2.32	Generación de una distribución mediante sucesivos cortes del dominio de ubicación.	56
Figura 2.33	Proceso de agrupamiento de actividades y dendograma representativo.	58
Figura 2.34	Dendograma + información de cortes = árbol de cortes.	58
Figura 2.35	Resultado de la aplicación de los diferentes operadores de corte sobre un nodo.	59
Figura 2.36	Recorrido preorden de un árbol de cortes. Adaptado de [Santamarina, 95].	60
Figura 2.37	Generación de una distribución a partir de un árbol de cortes.	60
Figura 2.38	Obtención de diferentes distribuciones a partir de un árbol de cortes mediante la modificación de los operadores de corte.	61
Figura 2.39	Distribución obtenida mediante estructuras de bahía. Las 17 actividades se han distribuido en 5 bahías.	62
Figura 2.40	Descomposición de la matriz de localización en el Space Partitioning Method de Kim y Kim [Kim et al., 98].	63
Figura 2.41	Formulación analítica del problema y distancia rectilínea entre actividades. Adaptado de [Santamarina, 95].	64
Figura 2.42	Clasificación de los métodos en función de la técnica empleada para la resolución.	66
Figura 2.43	Posible estrategia de relleno en ALDEP.	70
Figura 2.44	Colocación de actividades en CORELAP.	70
Figura 2.45	Intercambio de dos actividades en CRAFT.	72
Figura 2.46	Métodos de resolución empleados en la bibliografía. Adaptado de [Loiola et al., 04].	72

### CAPÍTULO 3

Figura 3.1	Escape de un óptimo local mediante la aceptación de configuraciones de mayor energía en el "Simulated annealing".	78
Figura 3.2	Simulated annealing aplicado a un problema de optimización (adaptado de [Santamarina, 95]).	80
Figura 3.3	Ciclos en la búsqueda tabú; la lista tabú impide que las situaciones a y b se alternen indefinidamente.	85
Figura 3.4	Diagrama de flujo de búsqueda tabú; memoria a corto plazo. Adaptado de [Youssef et al., 01].	86
Figura 3.5	Actualización de la lista tabú.	86
Figura 3.6	Intercambio de dos actividades adyacentes.	89
Figura 3.7	Entorno de una solución en el problema cuadrático de asignación multiárea.	90
Figura 3.8	Estrategia de intensificación.	92
Figura 3.9	Estrategia de diversificación.	93
Figura 3.10	Path Relinking en proceso de intensificación.	94
Figura 3.11	Path Relinking en proceso de diversificación.	95

Figura 3.12	Esquema general de un Algoritmo Evolutivo.	97
Figura 3.13	Pleitropía (a) y poligenia (b).	98
Figura 3.14	Relación entre el espacio de los genotipos y el de los fenotipos. Topografía de la función objetivo.	99
Figura 3.15	Algoritmos de hormigas	107
Figura 3.16	Esquema de una neurona.	109
Figura 3.17	Comunicación entre neuronas. a) Red neuronal. b) Sinapsis.	109
Figura 3.18	Neurona artificial.	111
Figura 3.19	Proceso entrada-salida en una neurona artificial. Adaptado de [Acosta-Buitrago et al., 05].	111
Figura 3.20	Representación simplificada de una neurona artificial.	112
Figura 3.21	Red neuronal con una sola capa oculta, r entradas y s neuronas. Adaptado de [Acosta-Buitrago et al., 05].	113
Figura 3.22	Red neuronal con tres capas ocultas.	113
Figura 3.23	Entrenamiento de una red neuronal.	114
Figura 3.24	Posible clasificación de las redes neuronales. Tomado de [Acosta-Buitrago et al., 05].	115

## CAPÍTULO 4

Figura 4.1	Estructura celular.	120
Figura 4.2	Analogías en los algoritmos genéticos. Adaptado de [Santamarina, 95].	123
Figura 4.3	Analogías en los algoritmos genéticos (II). Adaptado de [Santamarina, 95].	124
Figura 4.4	Analogías en los algoritmos genéticos (III). Adaptado de [Santamarina, 95].	124
Figura 4.5	Analogías en los algoritmos genéticos (IV). Adaptado de [Santamarina, 95].	125
Figura 4.6	Esquema general de un algoritmo genético.	1126
Figura 4.7	Posibles puntos de ruptura de un esquema. Adaptado de [Santamarina, 95].	130
Figura 4.8	Los dieciséis esquemas representativos de una cadena de longitud cuatro.	133
Figura 4.9	Selección por Ruleta.	144
Figura 4.10	Probabilidades de selección con (a) y sin (b) Rank Selection.	145
Figura 4.11	Proceso de selección-reemplazo en un SGA (adaptado de [Pérez, 04]).	145
Figura 4.12	Esquema de la aplicación de una estrategia elitista.	147
Figura 4.13	Esquema de un algoritmo genético con edades.	149
Figura 4.14	Efectos intensificadores y diversificadores de los operadores cruce y mutación.	151
Figura 4.15	Cruce monopunto.	152
Figura 4.16	Ejemplo de esquema no heredable mediante cruce monopunto.	152
Figura 4.17	Cruce bipunto.	153
Figura 4.18	Generación de uno de los descendientes en un cruce uniforme.	154

Figura 4.19	Actuación del operador inversión.	158
Figura 4.20	Cadenas representativas de individuos no factibles.	159
Figura 4.21	Resolución de infactibilidades mediante remapping fijo.	161
Figura 4.22	Meta-algoritmo genético. Los individuos de la población son, algoritmos genéticos.	165
Figura 4.23	Emulación del gradiente. El individuo original es sustituido por aquel que, obtenido variando el valor de un bit, proporcione un mayor descenso (ascenso) de la aptitud.	168

## CAPÍTULO 5

Figura 5.1	Obtención de diferentes distribuciones a partir de un árbol de cortes mediante la modificación de los operadores de corte.	175
Figura 5.2	Operadores de corte en [Tam, 92c]	176
Figura 5.3	Codificación de las distribuciones de un árbol de cortes en [Tam, 92c].	176
Figura 5.4	Orientación de actividades	178
Figura 5.5	Medición del incumplimiento formal en [Tam, 92c].	179
Figura 5.6	Mutación en [Tam, 92c].	180
Figura 5.7	Cruce en [Tam, 92c].	182
Figura 5.8	Codificación de un individuo propuesta por Tam (adaptado de [Tam et al., 98]).	185
Figura 5.9	Generación de árboles de cortes y codificación en cadenas en LAYAGEN.	186
Figura 5.10	Decodificación de cromosomas en LAYAGEN para obtener los árboles de corte que representan.	187
Figura 5.11	Generación de una población de $m$ árboles de corte (especies). Adaptado de [Santamarina, 95].	188
Figura 5.12	Distintas distribuciones generadas por un árbol de cortes.	189
Figura 5.13	Dos ejemplos del camino a recorrer de manera ascendente desde una actividad $j$ hasta el primer nodo común con otra actividad $i$ .	190
Figura 5.14	Posibles situaciones de $i$ en el subdominio dependiente de su nodo común con $j$ .	191
Figura 5.15	Actividades exteriores en sus subdominios y no adyacentes.	191
Figura 5.16	Cálculo del potencial de adyacencia entre actividades.	191
Figura 5.17	Cruce de dos especies en LAYAGEN para obtener híbridos interespecíficos. Casos de descendencia viable e inviable.	193
Figura 5.18	Inviabilidad de la aplicación de la mutación clásica en la primera fase de LAYAGEN.	194
Figura 5.19	Mutación en la primera fase de LAYAGEN	195
Figura 5.20	Mutación en la primera fase de LAYAGEN	195
Figura 5.21	Analogía entre la segunda fase de LAYAGEN y la influencia del medio externo en la expresión fenotípica.	196
Figura 5.22	Tipos de corte en el método LAYAGEN.	197
Figura 5.23	Codificación de las distribuciones de un árbol de cortes en LAYAGEN.	198
Figura 5.24	Cruce en la segunda fase de LAYAGEN	200
Figura 5.25	Ejemplos de aplicación del operador trasplante (tomado de [Al	203

	Hakim, 00]).	
Figura 5.26	Ejemplo de aplicación del operador trasplante sin cambio de posición de la rama transplantada (tomado de [Al Hakim, 00]).	204

## CAPÍTULO 6

Figura 6.1	Solución al problema de Armour & Buffa [Armour et al., 63] propuesta en [Wang et al., 05].	207
Figura 6.2	Solución a un problema de 12 actividades en [Shayan et al., 04].	208
Figura 6.3	Espacios de soluciones en métodos monofásicos (a) y bifásicos (b).	211
Figura 6.4	Distribución de actividades que requiere de un árbol de cortes desequilibrado.	212
Figura 6.5	Árbol de cortes básico.	214
Figura 6.6	Posibles configuraciones generadas por un corte en un árbol de cortes básico.	215
Figura 6.7	Medición de la forma de un dominio mediante ratios alto-ancho y mediante ángulos.	216
Figura 6.8	Codificación de las actividades.	218
Figura 6.9	Medición del incumplimiento formal de una actividad de orientación libre.	219
Figura 6.10	Medición del incumplimiento formal de una actividad de orientación fija.	220
Figura 6.11	Representación del incumplimiento formal de una actividad en función del ratio del dominio de partida.	222
Figura 6.12	Representación del incumplimiento formal de una actividad en función del ratio del dominio de partida con valores negativos permitidos.	222
Figura 6.13	Representación del incumplimiento formal de una actividad en función del ratio del dominio de partida con carácter potencial ( $p=2$ ).	223
Figura 6.14	Representación del incumplimiento formal de dos actividades generadas por el corte de un dominio en función del ratio del dominio de partida.	223
Figura 6.15	Representación del incumplimiento formal de dos actividades generadas por el corte de un dominio en función del ratio del dominio de partida, para las que no existe un intervalo de validez común.	224
Figura 6.16	Representación del incumplimiento formal de dos actividades generadas por un corte vertical u horizontal de un dominio en función del ratio del dominio de partida.	224
Figura 6.17	Representación de la suma de los incumplimientos formales de dos actividades generadas por un corte vertical y por un corte horizontal de un dominio en función del ratio del dominio de partida.	225
Figura 6.18	Potencial geométrico del árbol de cortes básico calculado mediante una estrategia acumulada.	226
Figura 6.19	Potencial geométrico del árbol de cortes básico calculado mediante una estrategia pesimista.	226
Figura 6.20	Potencial geométrico del árbol de cortes básico calculado mediante una estrategia optimista.	227
Figura 6.21	Árbol de cortes formado por un árbol básico y una actividad.	228
Figura 6.22	Sustitución de un árbol básico por una actividad equivalente.	228

Figura 6.23	Ratio de las actividades de un árbol de cortes básico-actividad en función del ratio del dominio de partida.	230
Figura 6.24	Incumplimiento formal de la actividad y potencial geométrico de la actividad ficticia de un árbol de cortes básico, en función del ratio del dominio inicial, en caso de cortes vertical y horizontal.	230
Figura 6.25	Potencial geométrico de un árbol de cortes básico-actividad en función del ratio del dominio de partida.	230
Figura 6.26	Distribuciones que cumplen los requerimientos geométricos con diferentes ratios del dominio inicial.	231
Figura 6.27	Distribuciones que cumplen los requerimientos geométricos con diferentes ratios del dominio inicial.	232
Figura 6.28	Posibles distribuciones generadas por un árbol de 3 actividades y ratio de las áreas destinadas a cada una.	233
Figura 6.29	Árbol de cortes formado por dos árboles básicos.	233
Figura 6.30	Sustitución de árboles básicos por actividades equivalentes	234
Figura 6.31	Árbol de cortes de 7 actividades y datos de las mismas.	235
Figura 6.32	Proceso de cálculo del potencial geométrico de un árbol de cortes genérico.	236
Figura 6.33	Incumplimientos formales de las actividades.	237
Figura 6.34	Potencial geométrico de los subárboles que conforman el árbol de cortes en función del ratio del dominio que los genera.	238
Figura 6.35	Potencial geométrico del árbol de cortes.	238
Figura 6.36	Potencial geométrico del árbol de cortes para ratio del dominio de ubicación de la planta no fijado.	241
Figura 6.37	Árbol de cortes de 7 actividades.	242
Figura 6.38	Estructura bifásica de LAYAGEN G.	243
Figura 6.39	Diagrama general del flujo de LG1.	245
Figura 6.40	Generación de árboles de cortes y codificación en cadenas en LAYAGEN.	247
Figura 6.41	Decodificación de cromosomas en LAYAGEN para obtener los árboles de corte que representan.	248
Figura 6.42	Cromosoma que representa un individuo no factible.	249
Figura 6.43	Falta de localidad en la codificación de los árboles de corte.	250
Figura 6.44	Generación de una población de "n" árboles de corte (especies). Adaptado de [Santamarina, 95].	251
Figura 6.45	Discretización de funciones en el cálculo del potencial geométrico de los árboles de corte.	253
Figura 6.46	Representación del error cometido al discretizar el potencial geométrico del árbol de cortes.	254
Figura 6.47	Error en la interpolación entre muestras del potencial geométrico del árbol de cortes.	254
Figura 6.48	Ejemplo de epistasia.	256
Figura 6.49	Cruce de dos especies en LAYAGEN para obtener híbridos interespecíficos. Casos de descendencia viable e inviable.	257
Figura 6.50	Efecto del operador cruce cuando existe similitud entre los progenitores.	258
Figura 6.51	Mutaciones en un cromosoma que afectan a genes cuyo alelo representa un nodo del árbol de cortes.	259

Figura 6.52	Analogía de la Selección por Ruleta.	261
Figura 6.53	Estrategia elitista en LG1.	263
Figura 6.54	Determinación del punto de cruce en el operador cruce de LG1.	265
Figura 6.55	Actuación del operador mutación en LG1.	266
Figura 6.56	Cromosomas con diferente sensibilidad a la mutación.	267
Figura 6.57	Actuación del operador mutación geométrica en LG1.	268
Figura 6.58	Medición de la convergencia en LG1.	269
Figura 6.59	Intensificación local de la búsqueda.	271
Figura 6.60	Entorno de una solución.	272
Figura 6.61	Procedimiento de intensificación local de la búsqueda.	272
Figura 6.62	Esquema de las fases genética y de búsqueda local de LG1.	273
Figura 6.63	Ratio recomendado para plantas con ratio variable.	274
Figura 6.64	Esquema general de LG2.	275
Figura 6.65	Codificación de las distribuciones de un árbol de cortes en LG2.	277
Figura 6.66	Distribuciones con actividades con diferente grado de incumplimiento de las restricciones geométricas.	279
Figura 6.67	Estrategia elitista en LG2.	280
Figura 6.68	Exploración de ratios en LG2.	283

## CAPÍTULO 7

Figura 7.1	Interfaz de introducción de datos del problema.	287
Figura 7.2	Interfase de parametrización y ejecución de LG1.	288
Figura 7.3	Influencia en la evolución de la función objetivo de cambios en la parametrización durante la ejecución.	289
Figura 7.4	Información sobre los potenciales de adyacencia de un árbol de cortes.	289
Figura 7.5	Interfase de parametrización y ejecución de LG2.	290
Figura 7.6	Introducción de datos para la automatización de la resolución de problemas.	291
Figura 7.7	Visor de resultados de experimentos automatizados.	292
Figura 7.8	Estructura de la red de ejecución distribuida.	292
Figura 7.9	Selección del papel de un equipo en la ejecución en red.	293
Figura 7.10	Ventana de control de la ejecución en red.	293

## CAPÍTULO 8

Figura 8.1	Red de ordenadores empleada en la resolución de los problemas de distribución en planta mediante la metodología propuesta.	297
Figura 8.2	Valor del coste del flujo de materiales en los experimentos E1.	304
Figura 8.3	Árbol de cortes empleado en los experimentos de parametrización de LG2.	305
Figura 8.4	Coste del flujo de materiales de los experimentos E-2 y número de actividades factibles de las soluciones óptimas.	309
Figura 8.5	Actividades factibles y coste geométrico en los experimentos E-2.	310

Figura 8.6	Generación de aparición del óptimo en los experimentos E-2.	310
Figura 8.7	Mejor solución obtenida en los experimentos E-2. El coste asociado al flujo de materiales entre las actividades es 8103,7.	311
Figura 8.8	Solución de mínimo coste relacional y máximo coste geométrico.	313
Figura 8.9	Mejores soluciones obtenidas en los experimentos E2 (I).	314
Figura 8.10	Mejores soluciones obtenidas en los experimentos E2 (yII).	315
Figura 8.11	Interfaz de usuario empleado en la implementación informática de LG2.	316
Figura 8.12	Tiempos de ejecución de LG2 y proporción respecto a LG1.	318
Figura 8.13	Tiempos de ejecución de las distintas actividades de LG1.	319
Figura 8.14	Porcentaje de tiempos de ejecución de las distintas actividades de LG1.	319
Figura 8.15	Modelización del área restringida del problema de Francis y White para su tratamiento mediante LAYAGEN G.	322
Figura 8.16	Solución a un problema de 8 actividades mediante el método jerárquico de Tam. Adaptado de [Tam et al., 91].	323
Figura 8.17	Complejidad del problema frente a número de actividades y dominancia de flujo (adaptado de [Block, 79]).	326
Figura 8.18	Porcentaje de complejidad de los problemas planteados.	328
Figura 8.19	Solución al problema de Francis y White obtenida mediante LAYAGEN G con ratio mínimo de las actividades 0,3.	329
Figura 8.20	Solución al problema de Francis y White obtenida mediante LAYAGEN G con ratio mínimo de las actividades 0,4.	330
Figura 8.21	Solución al problema de Francis y White obtenida mediante LAYAGEN G con ratio mínimo de las actividades 0,5.	330
Figura 8.22	Diversas soluciones al problema de Francis y White.	331
Figura 8.23	Solución al problema de Francis y White propuesta en [Francis et al., 74].	331
Figura 8.24	Solución al problema de Francis y White propuesta en [Contero-González, 95].	332
Figura 8.25	Solución al problema de Francis y White propuesta en [Santamarina, 95].	332
Figura 8.26	Soluciones del problema de Armour y Buffa en [Tate et al., 95].	334
Figura 8.27	Árbol de cortes capaz de generar la distribución propuesta en [Tate et al., 95] como solución al problema de Armour y Buffa.	334
Figura 8.28	Solución al problema de Armour & Buffa [Armour et al., 63] propuesta en [Wang et al., 05].	335
Figura 8.29	Solución del problema de Armour y Buffa en [Kim et al., 98].	335
Figura 8.30	Potencial geométrico del árbol de cortes capaz de generar la distribución propuesta en [Tate et al., 95] como solución al problema de Armour y Buffa.	335
Figura 8.31	Solución al problema de Armour y Buffa con actividades de ratio inferior a 1,2 y ratio de planta 0,45.	339
Figura 8.32	Solución al problema de Armour y Buffa con actividades de ratio inferior a 1,12 y ratio de planta 0,435.	340
Figura 8.33	Solución al problema de Tam de 30 actividades propuesta en [Tam et al., 91].	341
Figura 8.34	Solución al problema de Tam de 30 actividades con planta de ratio 1.	342



---

Figura 8.35	Solución al problema de Tam de 30 actividades con planta de ratio 0,95.	343
Figura 8.36	Representación de las proporciones de los dominios de ubicación de las distribuciones del problema de Tam de 30 actividades obtenidas mediante LAYAGEN G y el método jerárquico de Tam y Li.	343
Figura 8.37	Representación a escala de las actividades del problema propuesto y sus tolerancias formales.	346
Figura 8.38	Porcentajes de complejidad de los problemas resueltos.	348
Figura 8.39	Representación de la mejor solución obtenida en el experimento E3.	350
Figura 8.40	Mejores soluciones obtenidas en los experimentos E3.	351
Figura 8.41	Representación de la mejor solución obtenida en el experimento E3 considerado de ratio de planta libre.	352

## ÍNDICE DE TABLAS

---

Tabla 2.1	Movimiento de los medios directos de producción (ampliado de [Santamarina, 95]).	19
Tabla 2.2	Tipos de distribución en planta y tipos de operaciones a los que son aplicables habitualmente (tomado de [Santamarina, 95]).	23
Tabla 2.3	Características de los tipos básicos de distribución en planta. Tomado de [Adam et al., 92] y [Santamarina, 95].	24
Tabla 3.1	Una clasificación de los criterios de aspiración. Adaptado de [Glover et al., 03].	89
Tabla 6.1	Flujo de materiales entre actividades por unidad de tiempo.	242
Tabla 6.2	Potenciales de adyacencia de las actividades.	242
Tabla 8.1	Parámetros de la primera fase de LAYAGEN-G.	299
Tabla 8.2	Parámetros de la segunda fase de LAYAGEN-G.	299
Tabla 8.3	Datos del problema de Armour y Buffa.	300
Tabla 8.4	Coste del flujo de materiales en el problema de Armour y Buffa.	301
Tabla 8.5	Parámetros empleados en los experimentos E1.	302
Tabla 8.6	Resumen de los resultados de los experimentos E1.	303
Tabla 8.7	Parámetros empleados en los experimentos E2.	307
Tabla 8.8	Resumen de los resultados de los experimentos E-2.	309
Tabla 8.9	Datos de los experimentos para la medición de tiempos.	317
Tabla 8.10	Tiempos de ejecución de las distintas actividades de LG1.	318
Tabla 8.11	Datos del problema de Francis y White.	322
Tabla 8.12	Flujos por coste del transporte de materiales entre actividades en el problema de Francis y White.	322
Tabla 8.13	Datos de las actividades del problema de Tam de 30 actividades.	324
Tabla 8.14	Flujo de materiales entre las actividades del problema de Tam de 30 actividades.	325
Tabla 8.15	Parámetros de ejecución para el problema de Francis y White.	329
Tabla 8.16	Coste de las soluciones del problema de Armour y Buffa en [Tate et al., 95].	333
Tabla 8.17	Parámetros de ejecución para el problema de Francis y White.	336
Tabla 8.18	Coste del transporte de materiales de las soluciones del problema de Armour y Buffa obtenidas mediante LAYAGEN G.	336
Tabla 8.19	Soluciones al problema de Armour y Buffa obtenidas mediante LAYAGEN G.	339
Tabla 8.20	Parámetros de ejecución para el problema de Tam de 30 actividades.	342
Tabla 8.21	Datos del problema con requerimientos formales diversos.	345
Tabla 8.22	Matriz de volumen*coste por unidad de distancia del transporte de materiales entre actividades en el experimento E3.	347
Tabla 8.23	Parámetros de ejecución empleados en el experimento E3.	349
Tabla 8.24	Resultados obtenidos en el experimento E3.	350





# 1

**Objetivos y alcance de la investigación**

# 1. OBJETIVOS Y ALCANCE DE LA INVESTIGACIÓN

## 1.1. Introducción

Las actividades industriales desarrolladas en entornos competitivos se rigen cada vez más por los condicionantes de un mercado exigente y selectivo, en el que la eficiencia en el desempeño de todas las facetas del proceso productivo se hace condición necesaria para la subsistencia de la empresa. El éxito vendrá condicionado, entre otros factores, por la optimización de los costes de producción y una flexibilización de los procesos que permita hacer frente a un entorno cambiante. Ya en la década de los 50, Maynard [Muther, 81] indica que los materiales, la maquinaria y los salarios están cada vez más uniformizados, y que es un adecuado diseño del resto de los *detalles* relacionados con la producción lo que permite asegurar los márgenes de beneficio. Uno de estos aspectos que debe diseñarse con esmero es la distribución de las diferentes actividades del proceso productivo en la planta. Muther va más allá, diciendo que la distribución en planta es un *fundamento* de la industria que puede condicionar su subsistencia.

El beneficio de una adecuada disposición de los medios productivos no sólo es económico. Una distribución ajustada debe contemplar entre sus criterios el bienestar, las condiciones laborales y la salud de los trabajadores. Además, la disminución de los costes productivos suele deberse, aunque no es el único motivo, a un menor consumo de energía en procesos de manutención y acopio de materiales, lo que supone indirectamente un menor coste medioambiental.

Al final de la década de los 50 y principios de la de los 60, comienzan los esfuerzos por sistematizar el proceso de obtención de soluciones al problema. Desde entonces y hasta ahora han surgido multitud de procedimientos de generación y evaluación de *layouts*<sup>1</sup>, diferenciados fundamentalmente por la modelización del problema, el número de criterios contemplados, y las técnicas de resolución empleadas. El problema de obtener una distribución en planta óptima de las actividades, que simultáneamente respete ciertas restricciones, no es trivial. Es el desarrollo de las herramientas informáticas el que proporciona el impulso definitivo para el desarrollo de técnicas capaces de afrontar problemas de cierta envergadura mediante el empleo de heurísticas y metaheurísticas.

Las técnicas metaheurísticas han supuesto un gran avance en este campo. El espacio de posibles soluciones a un problema de cierta envergadura es lo suficientemente grande, como para no poder ser abordado mediante una exploración exhaustiva del mismo. Frente a esto, un muestreo de dicho campo guiado de manera *inteligente* ha demostrado ser más eficiente. Continuamente se aportan mejoras en aspectos más o menos específicos de las diferentes metaheurísticas, mejorando su eficacia y su eficiencia.

Entre las formas de abordar el problema, algunas metaheurísticas se enfrentan al gran espacio de posibles soluciones dividiendo el problema en dos subproblemas. En una primera fase se acota el campo de soluciones creando una zona de búsqueda menor, y en una

---

<sup>1</sup> Término anglosajón ampliamente difundido en la bibliografía para referirse a la distribución en planta.

segunda fase se escruta esa zona de manera exhaustiva. El empleo de esta estrategia no está exento de cierto riesgo, dado que si la búsqueda se acota sobre una zona inadecuada del espacio de soluciones, la solución final será necesariamente inadecuada. Esto ha provocado que la tendencia mayoritaria sea realizar la búsqueda en una única etapa que permita alcanzar cualquier parte del espacio de soluciones. El presente trabajo parte de la premisa de que, si la primera fase de acotación de la búsqueda se realiza adecuadamente, las posibilidades de éxito se multiplicarán.

Ya se ha indicado que son múltiples los criterios a contemplar en el diseño de la distribución, sobre todo, si se desea que el resultado sea ajustado a la realidad y que su implantación no requiera de grandes modificaciones. Sin embargo, gran parte de los autores y de las técnicas de resolución del problema que éstos proponen afrontan el problema desde un punto de vista monocriterio. En general, es la minimización de la distancia a recorrer por el flujo de materiales entre actividades el que se considera como criterio fundamental.

Entre las condiciones que debe cumplir una distribución para poder implantarse sin un gran reajuste, está que el área asignada a las actividades observe determinadas restricciones. Fundamentalmente que el tamaño de dicha área sea suficiente para albergar la actividad, y que la geometría de la misma permita su normal desempeño. Difícilmente es posible llevar a la práctica una solución en la que la forma de las actividades es irrealmente esbelta, o está desagregada, o es muy compleja. Sin embargo, algunas de las distribuciones obtenidas por métodos muy extendidos no son suficientemente estrictas en este sentido, dando por buenas soluciones impracticables. Si el criterio que guía dichas soluciones es minimizar la distancia entre actividades con elevado flujo de materiales, y posteriormente su implantación requiere de profundas modificaciones, es probable que la distribución realmente implantada no cumpla con criterio alguno.

En el presente trabajo, y tras un exhaustivo análisis del estado de la cuestión, se propondrá un método para la resolución del problema de la distribución en planta que considere múltiples criterios en la evaluación de la calidad de las soluciones, y que resulte especialmente eficaz en el respeto de las restricciones geométricas sin perder eficiencia en la consideración del resto de los criterios. Se plantea la exploración del espacio de soluciones en dos fases, una de acotación de la búsqueda y otra de búsqueda exhaustiva, mediante sendos algoritmos evolutivos que incorporen procedimientos de guiado de la exploración que en la bibliografía han demostrado su eficacia.

## **1.2. Objetivos de la investigación**

El objetivo primordial de la investigación es desarrollar un método eficiente que permita obtener distribuciones en planta de actividades industriales de elevada calidad bajo múltiples criterios, estableciendo como fundamental e irrenunciable, que el área asignada a las diferentes actividades cumplan estrictamente las restricciones geométricas impuestas. Para lograrlo, se deben alcanzar previamente los siguientes objetivos particulares:

- Llevar a cabo un análisis del estado del arte de los métodos de resolución del problema de distribución en planta, los diferentes enfoques y planteamientos, y los resultados que se obtienen con cada uno de ellos.

- Estudiar el funcionamiento y el estado de las técnicas heurísticas y metaheurísticas empleadas en la resolución del problema de distribución en planta.
- Realizar un profundo análisis de la teoría en la que se asientan los algoritmos evolutivos, como forma de llevar a cabo una correcta aplicación al problema en cuestión.
- Definir indicadores de la calidad de los resultados obtenidos, fundamentalmente desde el punto de vista geométrico, que permitan salvar la incertidumbre existente en la primera fase del proceso de búsqueda de soluciones mediante el procedimiento que se plantea.
- Desarrollar una aplicación informática que implemente el algoritmo propuesto, y que permita automatizar el proceso de resolución de problemas de distribución, aprovechando el potencial de cálculo de una red de ordenadores.
- Llevar a cabo una correcta parametrización del algoritmo desarrollado.

### **1.3. Metodología y estructura de los contenidos**

El presente trabajo de investigación se ha desarrollado siguiendo el esquema del método científico tradicional: a partir del análisis detallado del problema en cuestión, y de una revisión exhaustiva de los métodos de resolución existentes en la bibliografía y sus bases de funcionamiento, se han concluido una serie de principios generales que han permitido plantear las hipótesis de trabajo. Con base en dichas hipótesis se ha desarrollado una metodología de resolución del problema con la que posteriormente se ha experimentado, llegando a demostrar la validez de las hipótesis de partida. Se han extraído las conclusiones pertinentes y, por último, mediante el presente documento, se procede a la comunicación de los resultados. Además de en esta memoria, los frutos de la investigación desarrollada quedan plasmados una aplicación informática que implementa la metodología propuesta de forma tal, que resulta de fácil aplicación al planificador de actividades industriales. En cada una de las fases antes mencionadas se han empleado los recursos materiales y los métodos que se irán exponiendo en cada capítulo. Los capítulos guardan correspondencia con las fases en contenidos y secuencia, permitiendo con la lectura seguir el desarrollo de la investigación.

La presente tesis doctoral divide su contenido en nueve capítulos. El primer y presente capítulo, **Objetivos y alcance de la investigación**, recoge los objetivos del trabajo desarrollado y la estructuración de los contenidos de la memoria. En los cuatro capítulos siguientes se realiza una revisión del estado del arte de los métodos de resolución del problema de la distribución en planta de actividades industriales. Esta revisión sigue un esquema y se ha estructurado de manera lógica, procediendo de “lo general” a “lo particular”. Así, en el capítulo 2, se aborda la **distribución en planta** de actividades industriales, se analiza la relevancia de la cuestión para el sector industrial, se estudian los diferentes planteamientos explotados para abordar el problema, y se examinan las diversas modelizaciones y la variedad de estrategias de resolución surgidas durante casi cinco décadas de aportaciones bibliográficas. Tras este análisis de la cuestión a nivel estratégico,



en el capítulo 3, **Metaheurísticas y redes neuronales para la distribución en planta de actividades industriales**, se centra el estudio sobre las técnicas más recientes y prometedoras para la resolución del problema, analizando los principios y bases de funcionamiento de los procedimientos de búsqueda de soluciones denominados, quizá eufemísticamente, inteligentes. El capítulo 4, **Algoritmos genéticos: funcionamiento y bases teóricas**, la revisión se centra sobre la técnica que se empleará en la metodología resultante de este trabajo. Los algoritmos genéticos son los procedimientos metaheurísticos con una base teórica más sólida, cuyo conocimiento es indispensable para aprovechar todo su potencial exploratorio. Finalmente, y descendiendo ya a nivel operativo, el capítulo 5, **Algoritmos genéticos aplicados a la distribución en planta**, estudia diferentes aproximaciones a la resolución del problema de distribución en planta mediante el empleo de estos algoritmos. Las conclusiones extraídas de este análisis servirán de base a la metodología propuesta.

A partir de las conclusiones extraídas en los capítulos precedentes, el capítulo 6, **Metodología propuesta**, presenta un procedimiento de resolución del problema de distribución que cubre los objetivos marcados al inicio del trabajo. Para comprobar la realidad del alcance de los objetivos, validar las hipótesis que han servido de base a la metodología y transformar ésta en una herramienta útil al planificador, se requiere la implementación informática del método, cuestión que se expone en el capítulo 7, **Implementación informática de LAYAGEN G**. Con esta herramienta y los problemas tipo que en la bibliografía sirven habitualmente para medir la aptitud de las técnicas de resolución, se demuestra en el capítulo 8, **Validación experimental de la metodología propuesta**, la capacidad del método propuesto para obtener soluciones que superan los mejores resultados publicados a dichos problemas. Finalmente, en el último capítulo, **Conclusiones y trabajos futuros**, se exponen ciertas conclusiones extraídas de la investigación llevada a cabo, y se esbozan líneas de investigación futura que, a la vista de dichas conclusiones, parecen resultar especialmente prometedoras.



# 2

Distribución en planta

## 2. DISTRIBUCIÓN EN PLANTA.

### 2.1. Introducción

En un mercado dominado por la competencia y la demanda, que exige gran variedad de productos con ciclos de vida cada vez más cortos, las empresas manufactureras tratan de adaptar sus procesos de fabricación implementando sistemas flexibles que permitan hacer frente a la incertidumbre que esta situación genera. Lograr la eficiencia y la flexibilidad demandada pasa necesariamente por una correcta ordenación de los medios productivos que permita, no sólo hacer frente con éxito a las situaciones actuales, sino también, a posibles escenarios futuros.

Un sistema productivo puede asimilarse a un proceso de transformación que convierte una serie de insumos en un determinado bien o servicio. Dicho proceso de transformación comprende un conjunto de operaciones diversas, tanto de tipo productivo sobre los insumos, materiales y productos (tratamiento, transformación, almacenamiento, inspección...), como de gestión de la información asociada al propio proceso (toma de decisiones, control de la producción, planificación, dirección...). La *Dirección de Operaciones* se puede definir como el diseño, la gestión del funcionamiento y la mejora de los sistemas de producción que crean los bienes o servicios de la compañía.

Los problemas que debe afrontar la *Dirección de Operaciones* pueden agruparse en dos categorías [Lario Esteban, 93]<sup>2</sup>: las relacionadas con el *Diseño del Sistema Productivo*, y las relacionadas con la *Gestión del Sistema Productivo*.

El Diseño del Sistema Productivo aborda:

- el diseño del producto (o servicio);
- la planificación de las capacidades productivas requeridas;
- la selección del equipo y el proceso;
- la localización geográfica de las unidades productivas y logísticas;
- la distribución en planta de los medios de producción;
- la selección de proveedores;
- la diseño de los sistemas de distribución;
- la definición del sistema de aseguramiento de la calidad;
- la selección de las tecnologías de información;
- el establecimiento de sistemas de control del sistema productivo;

---

<sup>2</sup> Otro criterio de agrupación muy extendido es en los tres niveles básicos de decisión: decisiones estratégicas, tácticas y operativas.

- y el estudio del trabajo.

Las decisiones relacionadas con la Gestión de los Sistemas Productivos son del tipo: previsión de la demanda, planificación de producción y compras, gestión de inventarios, programación y control de la producción, gestión del aprovisionamiento, gestión de la distribución, definición de los sistemas de mantenimiento de renovación de equipos, etc.

El presente trabajo se centrará sobre una de las decisiones que debe tomar el planificador durante el diseño del sistema productivo: la distribución en planta de los medios productivos. Se hace necesario resaltar que la distribución en planta no es un subproblema aislado dentro del proceso de diseño de la actividad productiva; como se expondrá más adelante, existe una clara interrelación entre la distribución y el resto de decisiones de la dirección de operaciones, tanto en su vertiente de diseño del sistema como en la de la gestión del mismo.

Tompkins y White [Tompkins et al., 84] dividieron la planificación de una actividad industrial (a la que se llamará proyecto de actividad industrial) en cinco fases (Figura 2.1). Tras la selección del producto a fabricar y del sistema productivo, y de haber dimensionado el proceso y el volumen de producción, se procede a la localización o ubicación de la planta industrial seleccionando la zona de actuación, el suelo industrial y la parcela, en base a diferentes criterios (puntos de abastecimiento de materias primas, situación de los mercados, sistemas de comunicación, etc.). Tras esto se realiza una distribución de conjunto de la planta que servirá de base para la distribución detallada y la elaboración del proyecto de ejecución. En una última fase se procederá a ejecutar el proyecto.

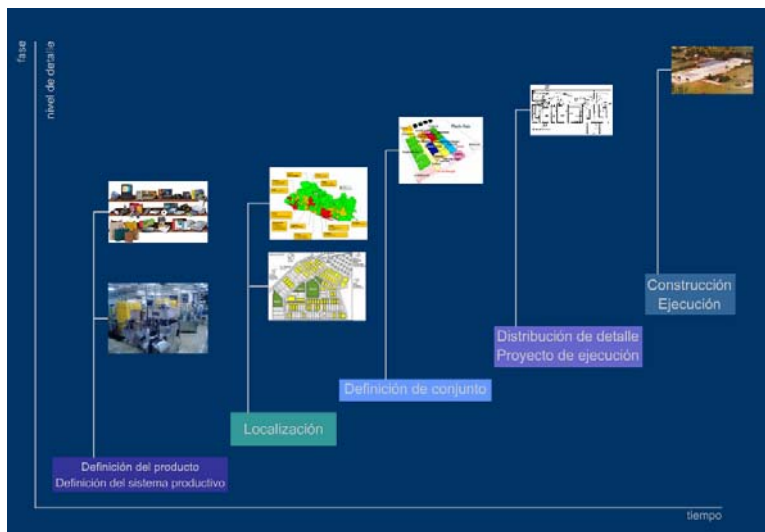


Figura 2.1: Fases de la planificación de una actividad industrial.

En el esquema habitual, la distribución en planta o layout, parte de considerar el número de actividades a realizar en el proceso productivo, el área requerida para el correcto desarrollo de dichas actividades, y las interrelaciones existentes entre ellas (flujos de materiales, necesidades de proximidad o alejamiento, etc.). A partir de dichos criterios se

obtiene una distribución ideal en la que quedan definidas la ordenación de actividades, la situación relativa entre ellas en el espacio de la planta y la forma de dicha planta (en el caso de que ésta no esté definida a priori). Basándose en dicha distribución ideal, y en una fase del proyecto de mayor nivel de detalle, se sintetiza la distribución real que será la que finalmente se lleve a la práctica. Para ello, se consideran factores como el aprovechamiento del espacio cúbico, los sistemas de mantenimiento y almacenaje o las técnicas constructivas disponibles. Esta distribución real determinará la tipología estructural escogida para la planta, el número y disposición de las aberturas, la altura de pilar y en definitiva la morfología de la nave, si es que ésta no existe y no está definida previamente.

Muther [Muther et al., 79] plantea con el método SPIF (Systematic Planning of Industrial Facilities) la planta industrial como un sistema compuesto por cinco subsistemas físicos interrelacionados entre ellos y con el entorno (Figura 2.2).

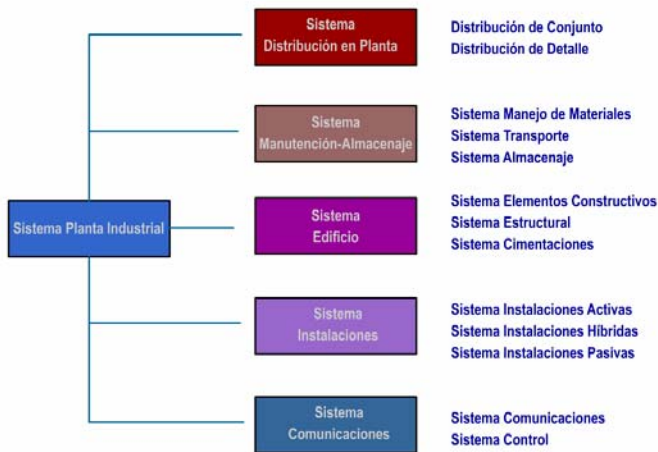


Figura 2.2: Sistema planta industrial y subsistemas que lo conforman.

Es el subsistema **distribución en planta** el que determina la ordenación de los medios productivos. Realizar dicha ordenación de manera eficiente no es un problema trivial debido al gran número de factores a considerar; una planta industrial es un sistema complejo en el que interactúan máquinas, materiales y hombres sirviéndose de un conjunto de instalaciones (sistemas de mantenimiento, almacenaje, servicios auxiliares, etc.). Es evidente que la forma de ordenar los medios productivos influye en la concepción del edificio industrial, en los medios de mantenimiento y almacenamiento a emplear, en las instalaciones y en los sistemas de comunicación. Respecto al edificio industrial, la distribución en planta condiciona los espacios y por tanto influye sobre la configuración arquitectónica del mismo (excepción hecha de aquellas distribuciones realizadas sobre plantas ya construidas o que deban adecuarse a las condiciones pre-existent).

Además de la complejidad de las relaciones del subsistema distribución en planta con el resto de subsistemas y con el entorno, la dificultad fundamental para obtener distribuciones flexibles y eficientes de los medios productivos, es la necesidad de contemplar y satisfacer

múltiples criterios. Como se expondrá posteriormente, el problema que se aborda posee un marcado carácter multicriterio, siendo simplista cualquier intento de abordarlo desde una perspectiva monocriterio.

La obtención de una distribución en planta adecuada a las necesidades de la empresa debe ser uno de los objetivos fundamentales de la arquitectura industrial. Mientras que una correcta ordenación de los medios de producción de la empresa, constituye para ésta una importante fuente de ventajas competitivas al tener incidencia directa sobre el coste de los productos fabricados, los tiempos de fabricación, el consumo de recursos energéticos, y sobre la capacidad de adaptación ante los cambios en la demanda, una distribución en planta incorrecta, constituye un grave problema que dificulta los procesos de fabricación, aumenta los costos de producción y que puede, llegado el momento, dificultar la subsistencia de la empresa.

*“La distribución en planta es un fundamento de la industria. Determina la eficiencia y, en algunos casos, la supervivencia de una empresa” [Muther, 81].*

Así pues, es absolutamente justificable la necesidad de un estudio detallado de las necesidades de la planta, de las características de su proceso productivo, de las características del mercado, y en general de todos los aspectos necesarios para desarrollar una correcta distribución en planta. A partir de los resultados de estos estudios debe obtenerse una distribución a largo plazo que traté de evitar modificaciones o redistribuciones que representan importantes costes, no sólo económicos sino también temporales, o bien, distribuciones fácilmente adaptables a las variaciones en la demanda del producto fabricado, o de los procesos productivos. Esta última aproximación, que contempla el problema de la distribución en planta desde una perspectiva temporal de condiciones variables [Hitchings, 70], en la que se trata de obtener distribuciones óptimas desde el punto de vista de la adaptabilidad a nuevas situaciones, es denominada *problema dinámico de distribución en planta*<sup>3</sup>. Este tipo de planteamiento fue introducido inicialmente por Rosenblatt [Rosenblatt, 86] y fue seguido posteriormente por multitud de autores (por ejemplo: [Balakrishnan et al., 92; Conway et al., 94; Lacksonen, 97; Baykasoglu et al., 01]).

El problema de la distribución en planta, sobre todo en la fase de distribución de conjunto, ha sido abordado por múltiples autores desde diversas perspectivas, empleando técnicas procedentes de otros ámbitos o desarrollando herramientas específicas para ello. En cualquier caso el problema está lejos de ser completamente resuelto, puesto que las soluciones obtenidas con los métodos existentes no son trasladables a una distribución detallada directamente implementable. El problema, en caso de abordarlo con cierto rigor, es intrínsecamente complejo debido a su carácter multicriterio, y a la naturaleza cuadrática de la función objetivo resultante de la formulación matemática del mismo. Por otra parte, la modelización del comportamiento de la planta y de las interacciones entre las diferentes actividades, la selección de los criterios a considerar y la calidad de la información de la que se dispone, introducen necesariamente inexactitudes que afectan a la inmediatez con que la distribución obtenida se puede trasladar a las siguientes fases de la implantación.

---

<sup>3</sup> En ocasiones, y en contraposición a la denominación inglesa “*dynamic facility layout problem*” (DFLP), al problema tradicional, que no consideran las posibles variaciones de las condiciones actuales para la generación de las distribuciones, se le denomina “*static facility layout problem*” (SFLP)

La falta de calidad geométrica de las soluciones obtenidas con los métodos existentes es quizá la mayor de las dificultades para una implementación directa. La consecuencia de la falta de control geométrico sobre los espacios asignados a cada una de las diferentes actividades, provoca que deban realizarse reajustes manuales que transformen la solución de conjunto obtenida, en una aplicable en la realidad.

## **2.2. Objetivos de la distribución en planta y definiciones del problema**

Como ya se dicho, una distribución en planta adecuada proporciona beneficios a la empresa que se traducen en un aumento de la eficiencia y por lo tanto de la competitividad. Esto es más así con la introducción de conceptos de fabricación recientes, como los sistemas de fabricación flexibles (FMS), la fabricación integrada por ordenador (CIM), o los sistemas de suministro de material Just-In-Time (JIT). Sea cual sea el sistema productivo, una correcta distribución en planta permite reducir los requerimientos de espacio y los desplazamientos de material, disminuye el volumen de trabajo en proceso y mejora el control de materiales y producto acabado.

Queda establecida, pues, la necesidad de una correcta distribución de las actividades productivas y los beneficios de ello esperables. Para lograr dichos beneficios es necesario que la solución obtenida cumpla con determinados objetivos.

Moore [Moore, 62] establece siete objetivos básicos a cumplir por la distribución en planta:

- simplificar al máximo el proceso productivo;
- minimizar los costes de manejo de materiales;
- tratar de disminuir la cantidad de trabajo en curso;
- aprovechar el espacio de la manera más efectiva posible;
- aumentar la satisfacción del operario y procurar la seguridad en el trabajo;
- evitar inversiones de capital innecesarias, y;
- aumentar el rendimiento de los operarios estimulándolos convenientemente

De manera general, Moore define la distribución en planta óptima, como aquella que proporciona la máxima satisfacción a todas las partes que se ven involucradas en el proceso de implantación.

Por su parte, Muther define el objetivo perseguido como lograr la mejor ordenación desde el punto de vista económico, de las áreas de trabajo y del equipo, siendo ésta además segura y satisfactoria para los empleados. Para este autor una buena distribución debe traducirse necesariamente en una disminución de los costes de fabricación, y para lograr esto, es necesario plantearse los siguientes objetivos durante su definición:

- reducir los riesgos para la salud y velar por la seguridad de los trabajadores;
- elevar la moral y la satisfacción del operario;



- incrementar la producción;
- disminuir los retrasos en la producción;
- minimizar las necesidades de espacio (tanto el destinado a producción como el necesario para almacenamiento o servicios);
- disminuir el tránsito de materiales;
- lograr un uso eficiente de la maquinaria, la mano de obra y los servicios;
- disminuir los tiempos de fabricación y la cantidad de material en proceso;
- reducir el trabajo administrativo y el trabajo indirecto en general;
- facilitar la supervisión;
- disminuir la confusión y la congestión;
- disminuir el riesgo para el material o su calidad;
- facilitar los ajustes o los cambios en el proceso;
- facilitar labores de mantenimiento, condiciones sanitarias, control de costes, y en general otros objetivos diversos.

Muther [Muther, 81] condensa la lista de objetivos anteriores en los siguientes seis objetivos básicos:

1. Integración conjunta de todos los factores que afectan a la distribución.
2. Movimiento del material según distancias mínimas.
3. Circulación del trabajo a través de la planta.
4. Utilización efectiva de todo el espacio.
5. Satisfacción y seguridad de los trabajadores.
6. Flexibilidad en la ordenación que facilite ajustes posteriores.

Autores más recientes, como por ejemplo Dowlatahahi [Dowlatahahi, 94], proporcionan listas de objetivos similares a los ya expuestos, haciendo especial hincapié en la minimización de los costes de operación y de mantenimiento, de los riesgos y las molestias; en aumentar el uso efectivo del espacio, la flexibilidad de la organización y el cumplimiento de las diferentes normativas; en proporcionar a los empleados comodidad seguridad y confort; en facilitar el flujo de operaciones, la organización y la toma de decisiones; y sobre todo, en la necesidad de la flexibilidad de la distribución.

Este último aspecto, la flexibilidad, ha ido adquiriendo paulatinamente una mayor importancia pasando a ser un objetivo primordial. Se entenderá que una distribución es flexible si puede ser ajustada o reordenada en poco tiempo, con poco esfuerzo, y con poca penalización en el coste y en el rendimiento [Upton, 94], para adaptarse tanto a variaciones del entorno económico, social o tecnológico de la empresa, como a reajustes internos de la planta. Una distribución en planta flexible será capaz de responder con la máxima rapidez y el mínimo coste, a cambios como descubrimientos científicos, mejoras en las comunicaciones, avances de la tecnología, mejoras de los procesos productivos, variaciones

en la legislación medioambiental o laboral, demandas de nuevas tipologías de productos, etc. Según Upton, la flexibilidad es de carácter multidimensional y debe ser entendida desde diversos puntos de vista. Así, este autor habla de flexibilidad del producto, de determinación de itinerarios, de composición, funcional, de estado, de volumen, de programa, a largo plazo, a corto plazo, de expansión, de maquinaria, de mano de obra, de proceso, de instalaciones, o de modificaciones del diseño.

Conocidos los objetivos que, según diversos autores, debe cumplir una distribución adecuada de los medios de producción, es necesario proporcionar una definición del problema consistente en obtener dicha distribución. La revisión bibliográfica sobre el tema ofrece diferentes definiciones del problema de distribución en planta, que difieren únicamente en aspectos particulares del mismo (una profusa relación de definiciones del problema puede consultarse en [Kusiack et al., 87]).

*“La distribución en planta implica la coordinación física de los elementos industriales. Esta ordenación, ya practicada o en proyecto, incluye, tanto los espacios necesarios para el movimiento del material, almacenamiento, trabajadores indirectos y todas las otras actividades o servicios, como el equipo de trabajo y el personal de taller.”* [Moore, 62]

*“La distribución en planta es el plan, o el acto de planificar, el ordenamiento óptimo de las actividades industriales, incluyendo personal, equipo, almacenes, sistemas de manutención de materiales, y todos los otros servicios anexos que sean necesarios para diseñar de la mejor manera posible la estructura que contenga estas actividades. [...] se trata de hallar una ordenación de las áreas de trabajo y del equipo que sea la más económica para llevar a cabo el proceso productivo, al mismo tiempo, que la más segura y satisfactoria para los operarios y para el entorno de la planta industrial [...] de modo que sea posible fabricar los productos con un coste suficientemente reducido para poder venderlos con un buen margen de beneficio en un mercado de competencia.”* [Muther, 81].

*“Los problemas de distribución en planta son un grupo de problemas de optimización consistentes en la partición de una región plana de dimensiones conocidas (generalmente rectangular) en departamentos de área conocida, de tal manera que se minimice el coste asociado con las interacciones previstas entre dichos departamentos. Éstos costes pueden deberse al transporte (incluyendo costes asociados con la construcción de los sistemas de manutención), o preferencias relativas a la adyacencia entre departamentos.”* [Tate et al., 95]

*“El problema de la distribución en planta consiste en determinar la distribución más eficiente de un número de departamentos indivisibles con requerimientos de área desigual en el interior de una instalación. El objetivo es minimizar los costes del transporte de materiales dentro de la planta considerando dos grupos de restricciones: los requerimientos de área y las restricciones de localización de los departamentos (no pueden solaparse, deben ser colocados en el interior de la planta, y algunas pueden necesitar una localización fija o no pueden ser colocados en regiones específicas).”* [Meller et al., 96c]

*“La distribución en planta consiste en resolver el problema de situar todos los componentes físicos que intervienen en un proceso de fabricación de modo que su comportamiento sea óptimo desde el mayor número de puntos de vista posibles, y es un problema que en todas las plantas industriales se ha de resolver”* [Gómez-Senent, 97].

*“El problema de la distribución en planta consiste en la disposición física de un número*

*dado de departamentos o máquinas con una configuración determinada. En el contexto de las empresas manufactureras, el objetivo es minimizar el coste del transporte de materiales requeridos entre los diferentes departamentos” [Mavridou et al., 97]*

*“El problema de la distribución en planta consiste en localizar la disposición óptima de un grupo de instalaciones sujetas a restricciones cualitativas o cuantitativas.” [Shayan et al., 04]*

Como se ha dicho, aunque las diferentes definiciones del problema lo abordan desde puntos de vista más o menos operativos, en general, en todas queda remarcado el carácter necesario, multifactorial y complejo del mismo.

## **2.2.1 Principios de la distribución en planta**

En el apartado anterior se han enumerado los objetivos que debe cumplir una distribución en planta según diversos autores. Según Muther, estos objetivos pueden resumirse y plantearse en forma de *principios*, sirviendo de base para establecer una metodología que permita abordar el problema de la distribución en planta de forma ordenada y sistemática [Muther, 81].

### **I. Principio de la integración de conjunto**

“la mejor distribución es la que integra a los operarios, los materiales, la maquinaria, las actividades, así como cualquier otro factor, de modo que resulte el compromiso mejor entre todas estas partes”.

### **II. Principio de la mínima distancia recorrida**

“en igualdad de condiciones, es siempre mejor la distribución que permite que la distancia a recorrer por el material entre operaciones será la más corta”.

### **III. Principio de la circulación o flujo de materiales**

“en igualdad de condiciones, es mejor aquella distribución que ordene las áreas de trabajo de modo que cada operación o proceso esté en el mismo orden o secuencia en que se tratan, elaboran, o montan los materiales”.

### **IV. Principio del espacio cúbico**

“la economía se obtiene utilizando de un modo efectivo todo el espacio disponible, tanto en vertical como en horizontal”.

### **V. Principio de la satisfacción y de la seguridad (confort)**

“en igualdad de condiciones, será siempre más efectiva la distribución que haga el trabajo más satisfactorio y seguro para los operarios, los materiales y la maquinaria”.

### **VI. Principio de la flexibilidad**

“en igualdad de condiciones, siempre será más efectiva la distribución que pueda ser ajustada o reordenada con menos costos o inconvenientes”.

Estos principios pueden servir de base para determinar los objetivos a cumplir durante la definición de la distribución en planta, y para medir el grado en que se ha logrado alcanzar dichos objetivos. No obstante, esta enumeración de principios fue realizada en 1981, y la

introducción de nuevos conceptos en los procesos de fabricación provoca que algunos de ellos hayan quedado desfasados.

### **2.3. La distribución en nueva planta frente a la reordenación de una planta existente**

El proyecto de implantación de una distribución en planta es un problema que no aparece únicamente en las plantas industriales de nueva creación. Durante el transcurso de la vida de una determinada planta, surgen cambios o desajustes que pueden hacer necesario desde reestructuraciones menores (reordenación de las actividades, cambios en los sistemas de manutención, cambios en cualquier tipo de servicio auxiliar...), hasta el traslado a una nueva instalación.

Un ejemplo del primer tipo sería la aparición de avances tecnológicos que pueden hacer necesaria la incorporación o sustitución de maquinaria en el proceso, lo cual da lugar a la generación de nuevas actividades o cambios en las áreas de trabajo de las actividades. Esto precisará de una nueva distribución de los diferentes elementos.

La necesidad de trasladar la actividad a una nueva planta se da cuando los problemas detectados son de una envergadura tal, que no pueden ser resueltos mediante modificaciones menores del actual sistema productivo.

Los distintos tipos de problemas de distribución en planta pueden clasificarse en función de la causa que determina su necesidad. Moore y Apple realizan una enumeración de posibles causas [Moore, 62; Apple, 77]:

- cambios en el diseño de los productos, aparición de nuevos productos o cambios en la demanda;
- equipos, maquinaria o actividades obsoletas;
- accidentes frecuentes;
- puestos de trabajo inadecuados para el personal (problemas ergonómicos, ruidos, temperaturas,...);
- cambios en la localización de los mercados;
- necesidad de reducir costes, etc.

Apple ofrece una recopilación de síntomas que pueden manifestar problemas que requieran de una reordenación o ajuste en la distribución en planta. Así, son síntomas significativos:

- que el recorrido de los productos sea excesivamente retorcido o que existan retrocesos en la circulación de los materiales (tanto materias primas como productos en curso o productos terminados);
- la existencia de pasillos retorcidos y distancias excesivas en los transportes;
- la falta de planificación de las operaciones y de coordinación entre los sistemas de

manutención y los procesos de producción;

- que las primeras operaciones estén alejadas de los centros de recepción o que las operaciones finales estén alejadas de los centros de expedición;
- que los puntos de almacenamiento estén dispersos o no definidos, con un exceso material o trabajo en curso;
- la falta o exceso de espacio de almacenaje o que exista material y desechos amontonados en lugares no adecuados;
- que el personal deba realizar excesivos desplazamientos y las actividades de producción representan el mínimo tiempo empleado por el operario;
- que exista falta de coordinación entre los medios de producción y los medios auxiliares de producción <sup>4</sup>;
- que la distribución no permita adaptarse a las diversas condiciones de producción.

Muther realiza una clasificación del problema de distribución en planta de acuerdo a su naturaleza planteando cuatro tipos fundamentales:

**Tipo 1:** *Proyecto de una planta completamente nueva.* Este caso se da fundamentalmente con la creación de la propia empresa, cuando ésta inicia la producción de un nuevo tipo de producto o cuando se expande trasladándose a un área nueva.

**Tipo 2:** *Expansión o traslado a una planta ya existente.* En este caso el proyectista debe afrontar el problema desde una perspectiva diferente; deberá adaptar una estructura organizativa, un proceso y unos medios productivos ya existentes a las características de un edificio industrial y unos servicios ya determinados.

**Tipo 3:** *Reordenación de una planta ya existente.* El proyectista se enfrenta ahora a las mismas restricciones existentes durante la generación de la distribución original: forma del edificio, dimensiones e instalaciones. En este caso se tratará de utilizar al máximo los elementos ya existentes, compatibilizándolos con los nuevos medios y métodos a introducir.

**Tipo 4:** *Ajustes menores en distribuciones ya existentes.* El proyectista debe tratar de resolver el problema sin cambiar de manera significativa la distribución de conjunto, interrumpiendo sólo lo imprescindible el proceso y realizando los ajustes mínimos necesarios. Este tipo de problema se da fundamentalmente cuando varían las condiciones de operación debido a variaciones en el diseño de las piezas producidas, a reajustes del volumen de producción o a cambios en la maquinaria o en los equipos, que en general pueden implicar un reajuste de las áreas de trabajo requeridas, del personal o del emplazamiento de la maquinaria y sistemas de manutención.

---

<sup>4</sup> Según la definición que de estos da Heredia en [De-Heredia, 81].

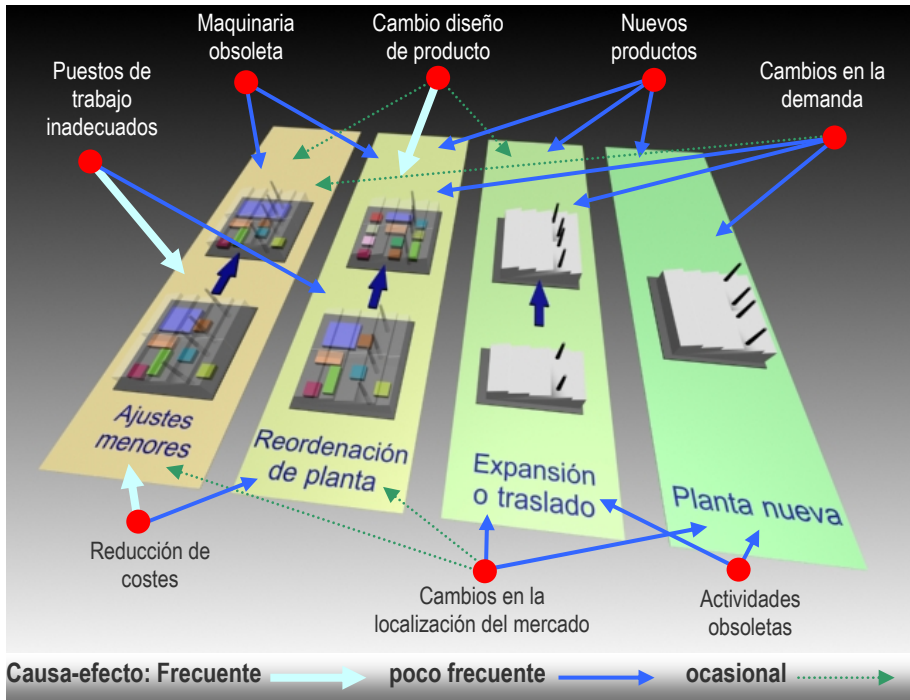























Figura 2.3: Tipos de problema de distribución y causas más frecuentes. Adaptado y ampliado de [Moore, 62]

## 2.4. Tipos básicos de distribución en planta de los medios de producción

La producción es el resultado de la acción combinada y coordinada de un conjunto de hombres que empleando maquinaria actúa sobre los materiales, modificando su forma, transformando sus características o combinándolos de diferentes maneras para convertirlos en un producto. El movimiento en los medios directos de producción es imprescindible para el desarrollo del proceso productivo. En algunos casos son los operarios los que se trasladarán a los puntos donde se realizan las diferentes operaciones; en otros casos es el material o incluso la maquinaria la que se desplaza. Las diferentes combinaciones de movimiento de los medios directos de producción pueden apreciarse en la Tabla 2.1

Desplazamiento	Ejemplo
  	Montaje de piezas pequeñas con maquinaria ligera.
  	Talleres mecánicos automatizados.
  	Construcción naval, construcción de grandes aviones, obras públicas...
  	Fabricación de utillaje en poca cantidad, instalación de piezas especiales...
  	Plantas de envasado, refineries de petróleo, talleres de maquinaria...
  	Operarios compartiendo maquinaria ligera, maquinaria portátil...
  	Control de calidad, supervisión de procesos, ordenación de materiales...

### Leyenda





	Maquinaria en movimiento		Operarios en movimiento		Material en movimiento
	Maquinaria estática		Operarios estáticos		Material estático

Tabla 2.1: Movimiento de los medios directos de producción (ampliado de [Santamarina, 95]).

Considerando como criterio exclusivamente al tipo de movimiento de los medios directos de producción, existen tres tipos clásicos de distribución en planta:

- **Distribución por posición fija.**
- **Distribución en cadena, en serie, en línea o por producto.**
- **Distribución por proceso, por función o por secciones.**

Además del tipo de movimiento de los diferentes medios de producción, otro factor que puede afectar determinadamente al tipo de distribución adoptada es la clase de operación de producción que se realiza en la actividad industrial. Las tres clases de operaciones de producción fundamentales son:

- **Elaboración o fabricación:** las operaciones van encaminadas a cambiar la forma del material inicial para obtener el producto final (inyección de plásticos,

embutición de metales...).

- **Tratamiento:** para obtener el producto final las operaciones transforman las características del material de partida (transformación del acero, fabricación de graña de plástico...).
- **Montaje:** para obtener el producto final las operaciones unen unas piezas a otras, materiales sobre las piezas o sobre un material inicial o base (elaboración de calzado o montaje de automóviles).

Desde el punto de vista de su influencia sobre la determinación de la distribución en planta más adecuada para cada caso, las operaciones de elaboración y tratamiento pueden considerarse como una única actividad dada su similitud, así pues, los tres tipos clásicos de distribución en planta combinados con los dos modos de operación de producción, dan lugar a seis tipos de distribución en planta básicos.

Por otra parte, considerando que existen tipologías clásicas de distribución difícilmente compatibles con determinadas operaciones, el número de posibles tipologías de distribución disminuye. No es corriente que las operaciones de montaje adopten distribuciones por proceso, dado que la maquinaria para este tipo de operación suele ser ligera y de fácil desplazamiento. Por otra parte, las operaciones de elaboración y tratamiento no suelen emplear distribuciones en posición fija, puesto que la maquinaria suele desempeñar un papel importante en este proceso y no suele ser fácil moverla. De esta manera se reducen a cuatro las tipologías básicas de distribución en planta.

### 2.4.1 Distribución por posición fija

La distribución por posición fija se emplea fundamentalmente en proyectos de gran envergadura en los que el material permanece estático, mientras que tanto los operarios como la maquinaria y equipos se trasladan a los puntos de operación. El nombre, por tanto, hace referencia al carácter estático del material.



*Figura 2.4: Distribución por posición fija: ensamble de un avión Airbus A340/600 en la planta de Airbus en Toulouse (Francia).*

Generalmente se trata de grandes productos de los que se fabrican pocas unidades de manera discontinua en el tiempo. Ésta es la disposición habitualmente adoptada en los astilleros durante la fabricación de grandes barcos, en la fabricación de grandes aviones o motores, o en la construcción de obras publicas.

Este tipo de distribución suele hacer necesaria una minuciosa planificación de las actividades a desarrollar, considerando la imposibilidad de movimiento del producto en proceso de fabricación y el gran tamaño de la maquinaria que suele ser empleada.



## 2.4.2 Distribución por proceso, por funciones, por secciones o por talleres.

Este tipo de distribución se escoge habitualmente cuando la producción se organiza por lotes. Ejemplo de esto serían la fabricación de muebles, la reparación de vehículos, la fabricación de hilados o los talleres de mantenimiento. En esta distribución las operaciones de un mismo proceso o tipo de proceso están agrupadas en una misma área junto con los operarios que las desempeñan. Esta agrupación da lugar a “talleres” en los que se realiza determinado tipo de operaciones sobre los materiales, que van recorriendo los diferentes talleres en función de la secuencia de operaciones necesaria. La secuencia requerida por cada tipo de producto fabricado suele ser diferente, por lo que un número elevado de productos distintos crea una gran diversidad de flujos de materiales entre talleres.




Figura 2.5: Distribución en planta por proceso.

La distribución por proceso, frente a otros tipos de disposiciones, ofrece una gran flexibilidad en cuanto a tipo de productos, siendo su eficacia dependiente del tamaño de lote producido. Permite una gran especialización de los trabajadores en tareas determinadas y que un mismo operario pueda controlar varias máquinas de manera simultánea.

Se requiere gran flexibilidad en los sistemas de transportes de materiales entre áreas de producción para poder hacer frente a variaciones en la producción. En general, frente a la ventaja que supone la posibilidad de procesar muchos productos diferentes, esta distribución es poco eficiente en la realización de las operaciones y la manutención.

## 2.4.3 Distribución por producto, en cadena o en serie

Cuando toda la maquinaria y equipos necesarios para la fabricación de un determinado producto se agrupan en una misma zona, siguiendo la secuencia de las operaciones que deben realizarse sobre el material, se adopta una distribución por producto. El producto

recorre la línea de producción de una estación a otra siendo sometido a las operaciones necesarias. Este tipo de distribución es la adecuada para la fabricación de grandes cantidades de productos muy normalizados.




Figura 2.6: Distribución en planta por producto.

Este sistema permite reducir tiempos de fabricación, minimizar el trabajo en curso y el manejo de materiales. Como contrapartidas se pueden citar la falta de flexibilidad, la gran inversión requerida, la poca tolerancia a fallos del sistema (la parada de una máquina puede parar toda la cadena) y la monotonía del trabajo para los operarios.

Ejemplos de distribución por producto se dan en las plantas de ensamblaje de automóviles, el embotellado o el envasado.

#### 2.4.4 Células de trabajo o células de fabricación flexible

Como ya se ha indicado las disposiciones por proceso destacan por su flexibilidad y las distribuciones por producto por su elevada eficiencia. Con la formación de células de trabajo se pretende combinar las características de ambos tipos de sistemas de fabricación, obteniendo una distribución flexible y eficiente.

Este sistema propone la creación de unidades productivas capaces de funcionar con cierta independencia denominadas *células de fabricación flexibles*. Dichas células son agrupaciones de máquinas y trabajadores que realizan una sucesión de operaciones sobre un determinado producto o grupo de productos. Las salidas de las células pueden ser productos finales o componentes que deben integrarse en el producto final o en otros componentes. En este último caso, las células pueden disponerse junto a la línea principal de ensamblaje, facilitando la inclusión del componente en el proceso en el momento y lugar oportunos. La distribución interna de células de fabricación puede realizarse a su vez por proceso, por producto o como mezcla de ambas, aunque lo más frecuente es la distribución por producto.

La introducción de las células de fabricación flexibles redundará en la disminución del inventario, la menor necesidad de espacio en planta, unos menores costes directos de producción, una mayor utilización de los equipos y participación de los empleados, y en algunos casos, un aumento de la calidad. Como contrapartida se requiere un gran desembolso en equipos que sólo es justificable a partir de determinados volúmenes de producción.

Las células de fabricación flexible son los elementos básicos de los *Sistemas de Fabricación Flexibles*, a los que se les puede otorgar la categoría de tipo de distribución en planta (*Distribución de Sistemas de Fabricación Flexibles*) [Tompkins et al., 84].

#### 2.4.5 Tipos básicos de distribución y características fundamentales

A modo de síntesis, la Tabla 2.2 recoge los cuatro tipos básicos de distribución en planta considerados anteriormente y los tipos de operaciones a los que se aplican habitualmente. Por su parte, la Tabla 2.3 presenta las características más relevantes de los distintos tipos de distribución atendiendo a diversos criterios (versión ampliada en [Santamarina, 95] de la original en [Adam et al., 92]).

Tipo de distribución	Operaciones
Por posición fija	• montaje (proyectos de gran envergadura)
Por proceso, por funciones, por secciones o por talleres	• elaboración o tratamiento
Por producto, en cadena o en serie	• montaje • elaboración o tratamiento
Distribución de sistemas de fabricación flexibles	• montaje • elaboración o tratamiento

Tabla 2.2: Tipos de distribución en planta y tipos de operaciones a los que son aplicables habitualmente (tomado de [Santamarina, 95]).

### 2.5. La distribución en planta como problema de diseño

Es una característica común de los problemas de diseño no tener una única solución válida bien definida. Más bien al contrario, es habitual que existan diversas alternativas de solución al mismo problema, cuyas valoraciones dependen en gran medida de los criterios que se empleen en la evaluación. Precisamente, el carácter multicriterio es otra característica presente en gran cantidad de problemas de diseño.

Este es el caso del problema de la distribución en planta, que ya Simon en 1975 [Simon, 75] establece como ejemplo de problema de diseño, caracterizando su proceso de solución como “*satisfacer*” más que “*optimizar*”. Es decir, encontrar soluciones a los problemas que satisfagan las necesidades que los plantearon, más que encontrar la mejor de todas las soluciones posibles.

Atendiendo a	Por producto	Por proceso	Posición fija	Sistemas Flexibles
<b>Producto</b>	<ul style="list-style-type: none"> <li>▪ Productos estándar</li> <li>▪ Alto volumen de producción</li> <li>▪ Demanda estable</li> </ul>	<ul style="list-style-type: none"> <li>▪ Varios productos con operaciones comunes</li> <li>▪ Volumen de producción variable</li> <li>▪ Demanda variable</li> </ul>	<ul style="list-style-type: none"> <li>▪ Bajo pedido</li> <li>▪ Bajo volumen de producción</li> </ul>	<ul style="list-style-type: none"> <li>▪ Series pequeñas y medianas (lotes)</li> <li>▪ Flexibilidad. Gama de productos amplia</li> </ul>
<b>Líneas flujo material</b>	<ul style="list-style-type: none"> <li>▪ Procesos lineales</li> <li>▪ Secuencias iguales para todos los productos</li> </ul>	<ul style="list-style-type: none"> <li>▪ Líneas entremezcladas, retorcidas</li> </ul>	<ul style="list-style-type: none"> <li>▪ No definidas</li> <li>▪ Material estático</li> </ul>	<ul style="list-style-type: none"> <li>▪ Cortas y sencillas</li> </ul>
<b>Cualificación del trabajador</b>	<ul style="list-style-type: none"> <li>▪ Rutinario y repetitivo</li> <li>▪ Especializado</li> </ul>	<ul style="list-style-type: none"> <li>▪ Intermedia</li> </ul>	<ul style="list-style-type: none"> <li>▪ Gran flexibilidad</li> <li>▪ Alta cualificación</li> </ul>	<ul style="list-style-type: none"> <li>▪ No hacen falta trabajadores</li> </ul>
<b>Necesidad de personal</b>	<ul style="list-style-type: none"> <li>▪ Gran cantidad</li> <li>▪ Planificación de material-operarios</li> <li>▪ Trabajo de control y mantenimiento</li> </ul>	<ul style="list-style-type: none"> <li>▪ Personal de planificación, manejo de materiales, producción y control de inventarios</li> </ul>	<ul style="list-style-type: none"> <li>▪ Para programación y coordinación</li> </ul>	<ul style="list-style-type: none"> <li>▪ Prácticamente nula, sólo supervisión</li> </ul>
<b>Manejo de materiales</b>	<ul style="list-style-type: none"> <li>▪ Predecible</li> <li>▪ Flujo sistemático y automatizable</li> </ul>	<ul style="list-style-type: none"> <li>▪ Flujo variable</li> <li>▪ Sistemas de manejo duplicados a veces</li> </ul>	<ul style="list-style-type: none"> <li>▪ Flujo variable</li> <li>▪ Equipos de manejo generales</li> </ul>	<ul style="list-style-type: none"> <li>▪ Síncrono, totalmente automático</li> </ul>
<b>Inventarios</b>	<ul style="list-style-type: none"> <li>▪ Mucha rotación de materiales, inventarios reducidos</li> </ul>	<ul style="list-style-type: none"> <li>▪ Largos</li> <li>▪ Mucho trabajo en curso</li> </ul>	<ul style="list-style-type: none"> <li>▪ Variables, continuas modificaciones</li> </ul>	<ul style="list-style-type: none"> <li>▪ Mucha rotación de materiales, inventarios reducidos</li> </ul>
<b>Uso de espacios</b>	<ul style="list-style-type: none"> <li>▪ Eficiente</li> </ul>	<ul style="list-style-type: none"> <li>▪ Poco efectivo</li> <li>▪ Mucho requerimiento por trabajo en curso</li> </ul>	<ul style="list-style-type: none"> <li>▪ Baja producción por unidad de espacio</li> </ul>	<ul style="list-style-type: none"> <li>▪ Muy efectiva</li> </ul>
<b>Inversión</b>	<ul style="list-style-type: none"> <li>▪ Elevada en equipos especializados</li> </ul>	<ul style="list-style-type: none"> <li>▪ Equipos y procesos flexibles</li> </ul>	<ul style="list-style-type: none"> <li>▪ Equipos y procesos móviles de propósito general</li> </ul>	<ul style="list-style-type: none"> <li>▪</li> </ul>
<b>Coste del producto</b>	<ul style="list-style-type: none"> <li>▪ Costes fijos elevados</li> <li>▪ Costes variables bajos (mano de obra y materiales)</li> </ul>	<ul style="list-style-type: none"> <li>▪ Costes fijos bajos</li> <li>▪ Costes variables elevados (material y transporte)</li> </ul>	<ul style="list-style-type: none"> <li>▪ Bajos costes fijos</li> <li>▪ Elevados costes variables (mano de obra y materiales)</li> </ul>	<ul style="list-style-type: none"> <li>▪ Costes fijos elevados</li> <li>▪ Costes variables bajos</li> </ul>

Tabla 2.3: Características de los tipos básicos de distribución en planta. Tomado de [Adam et al., 92] y [Santamarina, 95].

Así pues, como con todo problema de diseño, es posible abordar su resolución mediante un proceso sistemático y creativo, análogo al de cualquier otro problema de diseño en ingeniería de proyectos [González-Cruz, 01]. Este proceso, particularizado a la distribución en planta por González-Cruz sería el siguiente:

- Formulación del problema de diseño de distribución en planta: formulación de carácter amplio o de caja-negra.
- Análisis del problema de diseño de distribución en planta: considerando la identificación de los criterios más adecuados a emplear en la evaluación de las diversas alternativas de solución.
- Búsqueda de alternativas de diseño de distribuciones en planta: especificación de las alternativas de la caja-negra formulada en el primer paso del procedimiento.
- Evaluación de las alternativas de diseño de la distribución en planta: “medir” las diferentes alternativas mediante los criterios seleccionados.
- Selección del diseño de distribución en planta preferido.

- Especificación del diseño de distribución en planta que será instalado (distribución de detalle): definición de detalles y generación de documentación de implantación.

Tompkins y otros autores [Tompkins et al., 03] presentan un proceso más detallado particularizado en diez pasos reflejados en la Figura 2.7:




Figura 2.7: Aplicación del proceso de diseño en ingeniería a la distribución en planta.

Como se indicó en 2.1 la planta industrial posee un marcado carácter sistémico. Cada uno de los subsistemas que la componen interactúa y se relaciona con los restantes. Durante el proceso de diseño de la distribución es necesario considerar este aspecto, logrando obtener una solución satisfactoria no sólo para el subsistema “distribución en planta”, si no también para los restantes subsistemas (mantenimiento, almacenaje, edificio industrial, comunicaciones...).

Durante el diseño de la planta es necesario tomar una serie de decisiones fundamentales sobre el producto, el volumen de producción, el proceso de fabricación, los sistemas de mantenimiento y almacenaje, la propia distribución en planta y la planificación de la producción. Aunque el diseño de la distribución en planta es una etapa importante dentro del diseño global de la planta, está condicionado y a su vez condiciona las restantes decisiones de diseño.

En la Figura 2.8 se muestra una *aproximación secuencial*, en la que se toman de manera sucesiva las decisiones de diseño de la planta. El proceso se inicia estableciendo las disposiciones referentes al producto y al proceso de fabricación, y en base a éstas, se diseña la distribución en planta de los medios productivos, lo que a su vez proporciona la base para el diseño de los sistemas de mantenimiento y almacenaje; finalmente, tomadas todas estas decisiones se elabora el plan de producción.

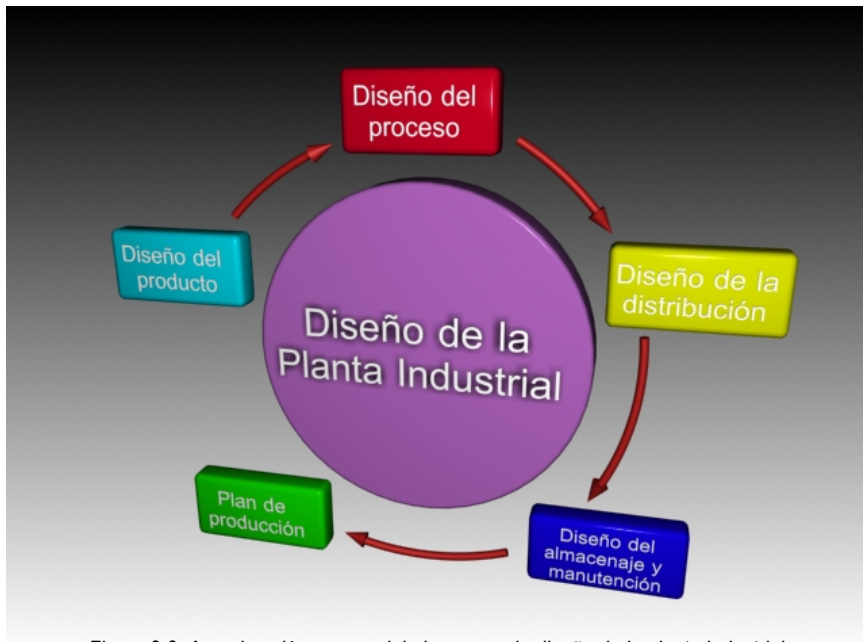


Figura 2.8: Aproximación secuencial al proceso de diseño de la planta industrial.

Dada la influencia que cada una de las decisiones de diseño adoptadas ejerce sobre el resto, frente a este modelo secuencial es preferible una *aproximación integrada* al proceso de diseño Figura 2.9. Siguiendo las líneas de la ingeniería concurrente, el diseñador de la planta debe trabajar coordinadamente con los profesionales más directamente implicados en cada una de las decisiones de diseño a adoptar. Además, dichas decisiones no se toman de

manera secuencial, sino más bien simultánea y recursiva, llegando a compromisos entre las necesidades derivadas de las sucesivas medidas adoptadas. El diseño del producto, del proceso, del plan de producción y del layout, es así una actividad coordinada en la que intervienen profesionales de cada ámbito, logrando soluciones integradoras de las diferentes necesidades a cubrir que mejoran costes, calidad, productividad, niveles de inventario, necesidades de espacio y transporte de materiales, tamaño de los edificios, etc.

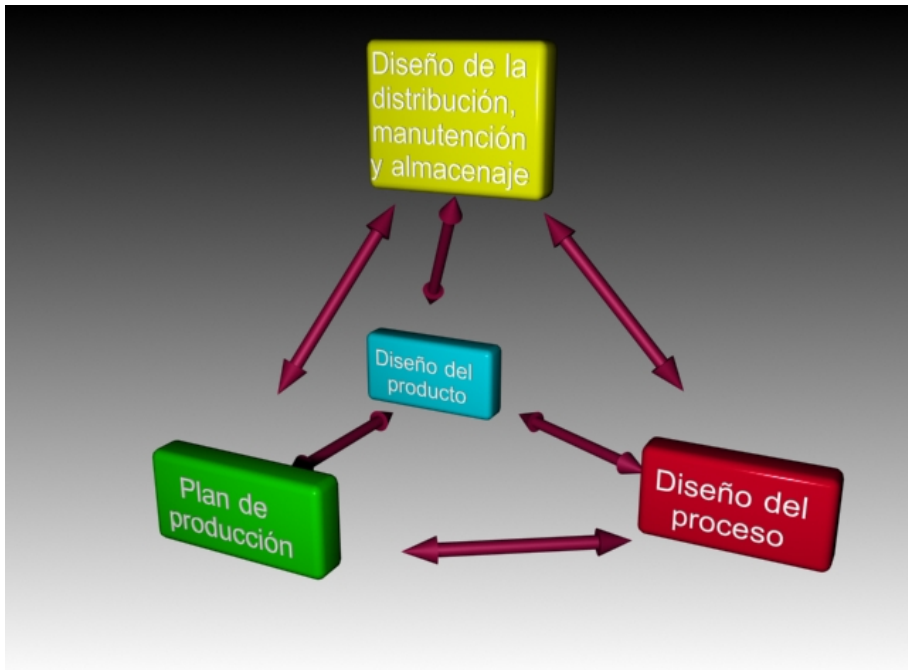


Figura 2.9: Aproximación integrada al proceso de diseño de la planta industrial.

### 2.5.1 Primeras aproximaciones metodológicas al problema de la distribución en planta

Los intentos por establecer una metodología que permitiera afrontar el problema de la distribución en planta de manera ordenada comienzan en la década de los 50 del siglo pasado. Sin embargo, es Muther en 1961, el primero en desarrollar un procedimiento verdaderamente sistemático, el *Systematic Layout Planning* (en adelante SLP) [Muther, 68] que establece una metodología aplicable a la resolución del problema independientemente de su naturaleza.

Los métodos precedentes al SLP son simples e incompletos si se considera el problema de distribución en planta con un mínimo de su complejidad, sin embargo, es necesario contemplarlas desde su contexto, con el final de la 2ª Guerra Mundial todavía próximo y con un crecimiento económico incipiente. Por otra parte, los métodos inmediatamente posteriores

al SLP son en muchos casos variantes de éste más o menos ampliadas, siendo el método de Muther el más difundido.

En los siguientes apartados se describen de manera breve algunas de estas metodologías, tratando el SLP de manera más extensa posteriormente.

### **2.5.1.1 El método de los pasos o etapas básicas de Immer**

Diversos autores coinciden en señalar a Immer como el primero en crear (en 1950) una metodología común para la resolución del problema de distribución en planta [Francis et al., 74; Tompkins et al., 84; Santamarina, 95].

La técnica de Immer es simple en extremo, estableciendo tres etapas o pasos en el proceso de resolución del problema:

**Etapla 1:** Plantear correctamente el problema a resolver.

**Etapla 2:** Detallar las líneas de flujo.

**Etapla 3:** Convertir las líneas de flujo en líneas de materiales.

El método atiende únicamente al principio de circulación o flujo de materiales (ver 2.2.1), y es aplicable solamente a los problemas de reordenación o ajuste menor de una distribución ya existente (problemas tipo 3 y 4 de los definidos en el apartado 2.3).

El propio Immer hace una descripción del análisis de un problema de distribución en los siguientes términos:

*“This analysis should be composed of three simple steps, which can be applied to any type of layout problem. These steps are: 1. Put the problem on the paper. 2. Show lines of flow. 3. Convert flow lines to machine lines.”*

### **2.5.1.2 El *sequence analysis* de Buffa**

El método desarrollado por Buffa en 1955 [Buffa, 55] puede considerarse un precursor del SLP, pudiendo establecerse con éste muchas similitudes. El procedimiento, tal y como se describe en [Santamarina, 95; González-Cruz, 01; González-García, 05] es el siguiente:

**Etapla 1:** Estudio del proceso, recopilación de datos referente a actividades, piezas y recorridos de éstas. Organización de estos datos en forma de Hojas de Ruta y análisis de los requerimientos del sistema productivo.

**Etapla 2:** Determinación de la secuencia de operaciones de cada pieza y elaboración de una tabla con dicha información (“*Sequence summary*”).

**Etapla 3:** Determinación de las cargas de transporte mensuales entre los diferentes departamentos que conforman el proceso. Esta información se recoge en una tabla denominada “Tabla de cargas de transporte” (“*Load summary*”).

**Etapla 4:** Búsqueda de la posición relativa ideal de los diferentes centros de trabajo. Para ello se emplea el “Diagrama Esquemático Ideal” (Figura 2.10). Este diagrama es un grafo en el que los diferentes departamentos son representados mediante círculos. Cada círculo está unido a los demás mediante líneas que representan el flujo de materiales entre los



respectivos departamentos. Sobre cada línea de unión se expresa mediante un número la carga de transporte que simboliza. La generación de este grafo debe tratar de minimizar el número de cruzamientos de las líneas de transporte de materiales y que los departamentos con mayor flujo entre ellos queden situados lo más próximos posible<sup>5</sup>. Este grafo se estudia y rehace, mejorándolo en los sucesivos intentos, hasta generar aquél que mejor logra los objetivos antes mencionados<sup>6</sup>.




Figura 2.10: Diagrama esquemático ideal en el Sequence Analysis de Buffa.

**Etapa 5:** Desarrollo del *Diagrama esquemático ideal* en un *Diagrama de bloques* en el que los diferentes departamentos ocupan sus áreas correspondientes y en el que se muestran las relaciones interdepartamentales.




Figura 2.11: Diagrama de bloques en el Sequence Analysis de Buffa.

<sup>5</sup> En este punto del proceso los departamentos se consideran sin área y son representados como puntos sin dimensiones.

<sup>6</sup> Este planteamiento dará lugar posteriormente a un conjunto de métodos de resolución del problema de distribución en planta basados en la teoría de grafos.

**Etapa 6:** Desarrollo del layout de detalle, en el que se especifican los sistemas de manutención, sistemas de almacenaje, sistemas auxiliares de producción y en definitiva, se establece la distribución que finalmente se implementará.

De nuevo, como ocurre con el método de Immer, es el flujo de materiales entre actividades el único criterio contemplado para establecer la disposición de las actividades. Sin embargo, ya en 1952, Cameron [Cameron, 52] había realizado las primeras referencias al uso de criterios cualitativos en el diseño de las distribuciones de las actividades, que sí consideraría posteriormente Muther en su SLP.

### 2.5.1.3 Propuestas metodológicas posteriores al SLP

Posteriormente a la propuesta del SLP (que será abordada en el próximo apartado), aparecen variantes más o menos detalladas de dicho método y otras propuestas que no alcanzan el grado de aceptación de la de Muther. Las más destacadas son expuestas a continuación.

#### 2.5.1.3.1 La propuesta de Reed

En 1961, Reed propone que el diseño de las instalaciones se realice siguiendo un planteamiento sistemático en 10 pasos [Tompkins et al., 84]:

- Estudiar el producto a fabricar.
- Determinar el proceso necesario para fabricar dicho producto y sus requerimientos.
- Preparar esquemas de planificación del layout: en los que se especifique información como las operaciones a realizar, los transportes y almacenajes necesarios, inspecciones requeridas, tiempos estándar de cada operación, selección y balance de maquinaria, requerimiento de mano de obra, etc.
- Determinación de las estaciones de trabajo.
- Determinar los requerimientos de áreas para almacenamiento.
- Determinación de la anchura mínima de los pasillos.
- Establecimiento de las necesidades de área para actividades de oficina.
- Consideración de instalaciones para personal y servicios.
- Planificar los servicios de la planta.
- Prever posibles futuras expansiones.

#### 2.5.1.3.2 El “*ideal systems approach*” de Nadler

La metodología propuesta por Nadler en 1965 [Tompkins et al., 84], se concibió en principio para el diseño de sistemas de trabajo, pero es aplicable, además, al diseño de la distribución en planta de instalaciones. El “Método de los sistemas ideales” es una aproximación jerárquica al diseño; es más una filosofía de trabajo que un procedimiento. Dicha aproximación se realiza partiendo del sistema ideal teórico que resuelve el problema

planteado, para ir descendiendo en el grado de idealidad/idoneidad hasta alcanzar una solución factible al problema. El planteamiento se esquematiza en la Figura 2.12.



Figura 2.12: Esquema del "ideal systems approach" de Nadler.

El *sistema teórico ideal* es un sistema perfecto de coste cero, calidad absoluta, sin riesgos, sin producción de deshechos y absolutamente eficiente. El *sistema ideal último* representa una solución que la tecnología no permite implementar en el momento actual, pero que previsiblemente lo será en el futuro. El *sistema ideal tecnológicamente viable* representa una solución para la que la tecnología actual puede dar respuesta, pero cuya implementación en la actualidad no es recomendable debido a algún motivo, por ejemplo, a su elevado coste. El *sistema recomendado* o *recomendable*, es una solución válida al problema con una aceptable eficiencia y coste, y cuya implementación es posible sin problemas. El *sistema real* o presente, es la implementación efectiva o existente de la solución.

Los sistemas convencionales de diseño realizan una aproximación contraria al problema. Comienzan con la solución existente y buscan mejoras a dicha solución. El método de Nadler parte de una solución ideal no factible, para aproximarse hacia la zona de factibilidad del espacio de soluciones del problema.

#### 2.5.1.3.3 La propuesta de Apple

Apple establece una secuencia muy detallada de pasos a realizar en el diseño del layout de la planta industrial [Tompkins et al., 84]. Esta propuesta es más específica y concreta que las anteriores, concretándose en los siguientes puntos:

1. Obtener los datos básicos del problema.
2. Analizar dichos datos.
3. Diseñar el proceso productivo

4. Proyectar los patrones de flujo de materiales
5. Determinar el plan general de manejo de materiales.
6. Calcular los requerimientos de equipamiento
7. Planificar los puestos de trabajo de manera individualizada
8. Seleccionar equipos de manutención específicos
9. Establecer grupos de operaciones relacionadas
10. Diseñar las relaciones entre actividades
11. Determinar los requerimientos de almacenamiento
12. Planificar los servicios y actividades auxiliares
13. Determinar los requerimientos de espacio
14. Localizar las actividades en el espacio total disponible
15. Escoger el tipo de edificio
16. Construir una distribución en planta maestra
17. Evaluar y ajustar la distribución en planta
18. Obtener las aprobaciones necesarias
19. Instalar la distribución obtenida
20. Hacer un seguimiento del funcionamiento de la instalación

### 2.5.2 El systematic layout planning (SLP) de Muther

El SLP fue desarrollado por Richard Muther [Muther, 68] como un procedimiento sistemático multicriterio y relativamente simple, para la resolución de problemas de distribución en planta de diversa naturaleza. El método es aplicable a problemas de distribución en instalaciones industriales, locales comerciales, hospitales, etc. Establece una serie de fases y técnicas que, como el propio Muther describe, permiten identificar, valorar y visualizar todos los elementos involucrados en la implantación y las relaciones existentes entre ellos.

EL SLP se asienta sobre la base de la información referente al problema a resolver para, a través de un proceso de cuatro etapas, obtener una distribución válida como solución al problema planteado. Además de las relaciones entre los diferentes departamentos, cinco tipos de datos son necesarios como entradas del método:

**Producto (P):** considerándose aquí producto también a los materiales (materias primas, piezas adquiridas a terceros, productos en curso, producto terminado, etc.)

**Cantidad (Q):** definida como la cantidad de producto o material tratado, transformado, transportado, montado o utilizado durante el proceso.

**Recorrido (R):** entendiéndose recorrido como la secuencia y el orden de las operaciones a las que deben someterse los productos.

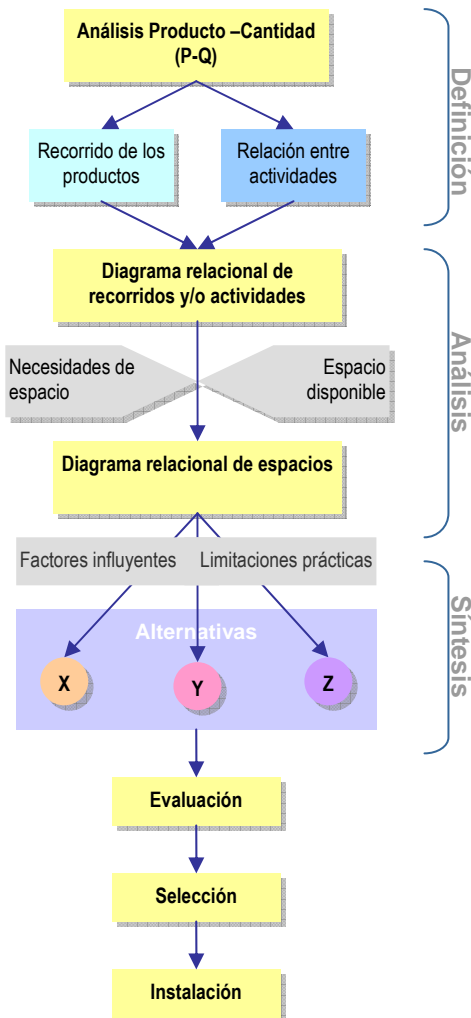


Figura 2.13: Esquema del systematic layout planning [Muther, 68].

**Servicios (S):** los servicios auxiliares de producción, servicios para el personal, etc.

**Tiempo (T):** utilizado como unidad de medida para determinar las cantidades de producto o material, dado que éstos se miden habitualmente en unidades de masa o volumen por unidad de tiempo.

Esta información es el punto de partida del proceso, y de la calidad de la misma depende el éxito en la búsqueda de soluciones al problema de distribución. Por tanto, debe dedicarse el tiempo y los recursos necesarios a su obtención.

La primera de las fases de aplicación del SLP es el análisis producto-cantidad.

### 2.5.2.1 Análisis P-Q

El análisis de la información referente a los productos y cantidades a producir es el punto de partida del método. A partir de este análisis es posible determinar el tipo de distribución adecuado para el proceso objeto de estudio. Muther recomienda la elaboración de una gráfica en forma de histograma de frecuencias, en la que se representen en abcisas los diferentes productos a elaborar y en ordenadas las cantidades de cada uno. Los productos deben ser representados en la gráfica en orden decreciente de cantidad producida. En

función del tipo de histograma resultante es recomendable la implantación de un tipo u otro de distribución. En el caso (a) (veáse Figura 2.14), en el que se produce una única unidad de un único producto, la distribución adecuada (e inevitable) es de posición fija, suponiendo que se trata de un proyecto de gran envergadura. La gráfica (b) hace recomendable una distribución en cadena. Este tipo de gráficas en las que pocos productos ocupan la mayor parte de la producción (principio de Pareto), indican series largas de producción homogénea, lo que hace recomendable distribuciones orientadas al producto. La existencia de gran diversidad de productos con niveles de producción similares (c), aconsejarían una

distribución de mayor flexibilidad orientada al proceso. Por último, situaciones como la señalada en la gráfica (d), pueden afrontarse con distribuciones mixtas, buscando la máxima flexibilidad y eficiencia, por ejemplo con células de fabricación flexible [Cuatrecasas-Arbós, 96].




Figura 2.14: Gráficas P-Q habituales de cada tipo de distribución en planta.

por cada proceso. Los *Diagramas multiproducto* son adecuados cuando se producen pocos productos. En ellos se indica únicamente la secuencia de operaciones a la que se somete cada pieza o producto. Las *Tablas matriciales* se emplean en el caso de producir gran cantidad de productos. Esta representación es una matriz cuadrada en la que tanto en filas como en columnas figuran las diferentes operaciones del proceso productivo. En las casillas se indica el número de veces que un producto circula desde la operación fila a la operación columna.

### 2.5.2.2 Análisis del recorrido de los productos

Se trata en esta fase de determinar la secuencia, la cantidad y el coste de los movimientos de los productos por las diferentes operaciones durante su procesado. A partir de la información del proceso productivo y de los volúmenes de producción, se elaboran gráficas y diagramas descriptivos del flujo de materiales. Estos pueden ser principalmente de tres tipos:

- Diagramas de recorrido sencillo
- Diagramas multiproducto
- Tablas matriciales

Cuando se producen muy pocos productos (o uno sólo) en cantidades pequeñas, se emplean *Diagramas de recorrido sencillo*, en los que quedan reflejados con exactitud los recorridos de cada producto

### 2.5.2.3 Análisis de las relaciones entre actividades

Conocido el recorrido de los productos, el proyectista debe plantearse el tipo y la intensidad de las interacciones existentes entre las diferentes actividades productivas, los medios auxiliares, los sistemas de manutención y los diferentes servicios de la planta. Estas relaciones no se limitan a la circulación de materiales, pudiendo ser ésta irrelevante o incluso inexistente entre determinadas actividades; por ejemplo, no suele existir circulación entre los medios auxiliares de producción. La no existencia de flujo material entre dos actividades no implica que no puedan existir otro tipo de relaciones que determinen, por ejemplo, la necesidad de proximidad entre ellas; o que las características de determinado proceso requieran una determinada posición en relación a determinado servicio auxiliar.

Entre otros aspectos, el proyectista debe considerar en esta etapa las exigencias constructivas, ambientales, de seguridad e higiene, los sistemas de manutención necesarios, el abastecimiento de energía y la evacuación de residuos, la organización de la mano de obra, los sistemas de control del proceso, los sistemas de información, etc.

Esta información resulta de vital importancia para poder integrar los medios auxiliares de producción en la distribución de una manera racional. Para poder representar las relaciones encontradas de una manera lógica y que permita clasificar la intensidad de dichas relaciones, se emplea la *tabla relacional de actividades* (Figura 2.15), consistente en un cuadro organizado en diagonal, en el que quedan plasmadas las necesidades de proximidad entre cada actividad y las restantes desde diversos puntos de vista. Es habitual expresar estas necesidades mediante el código de 6 letras representado en la figura.

En la práctica, el análisis de recorridos expuesto en el apartado anterior se emplea para relacionar las actividades directamente implicadas en el sistema productivo, mientras que la tabla relacional permite integrar los medios auxiliares de producción.

### 2.5.2.4 Diagrama relacional de recorridos y/o actividades

La información recogida hasta el momento, referente tanto a las relaciones entre las actividades como a la importancia relativa de la proximidad entre ellas, es recogida en un diagrama que Muther denomina *Diagrama relacional de recorridos y/o actividades*<sup>7</sup>. Éste pretende recoger la ordenación topológica de las actividades en base a la información de la que se dispone.

El diagrama es un grafo en el que las actividades son representadas por nodos unidos por líneas. Las líneas expresan la existencia de algún tipo de relación entre las actividades unidas. La intensidad de la relación quedará reflejada mediante números junto a las líneas (ver Figura 2.16 (a)) o mediante el correspondiente código ((ver Figura 2.16 (b)). La ordenación del grafo debe realizarse de manera que se minimice el número de cruces entre las líneas que representan las relaciones entre las actividades, o por lo menos entre aquellas que representen una mayor intensidad relacional. De esta forma, se trata de conseguir distribuciones en las que las actividades con mayor flujo de materiales estén lo más próximas posible (cumpliendo el principio de la mínima distancia recorrida, ver 2.2.1), y en las que la secuencia de las actividades sea similar a aquella con la que se tratan, elaboran o montan

---

<sup>7</sup> Este gráfico es similar al *Diagrama Esquemático Ideal* de Buffa (ver 2.5.1.2).






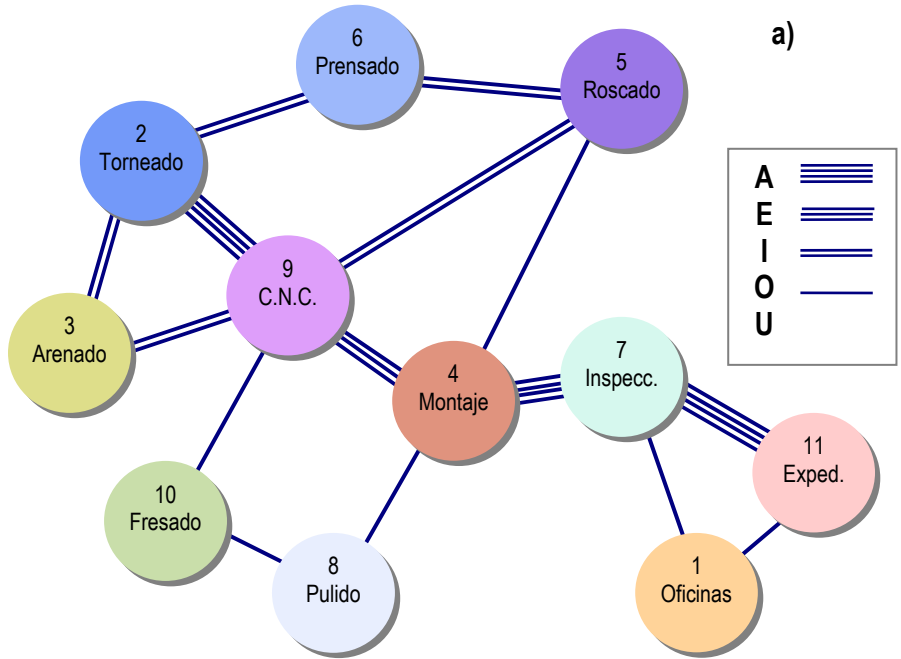


Figura 2.16: Diagrama relacional de actividades (a) y recorridos (b).

### 2.5.2.5 Diagrama relacional de espacios

La topología del diagrama relacional de recorridos y/o actividades recoge información sobre las necesidades de proximidad y las ubicaciones preferibles de cada actividad. Sin embargo, en dicho grafo los departamentos que deben acoger las actividades son adimensionales y no poseen una forma definida. El siguiente paso hacia la obtención de alternativas factibles de distribución es la introducción en el proceso de diseño, de información referida al área requerida por cada actividad para su normal desempeño. El planificador debe hacer una previsión, tanto de la cantidad de superficie, como de la forma del área destinada a cada actividad.

No existe un procedimiento general ideal para el cálculo de las necesidades de espacio. El proyectista debe emplear el método más adecuado al nivel de detalle con el que se está trabajando, a la cantidad y exactitud de la información que se posee y a su propia experiencia previa. El espacio requerido por una actividad no depende únicamente de factores inherentes a sí misma, si no que puede verse condicionado por las características del proceso productivo global, de la gestión de dicho proceso o del mercado. Por ejemplo, el volumen de producción estimado, la variabilidad de la demanda o el tipo de gestión de almacenes previsto pueden afectar al área necesaria para el desarrollo de una actividad. En cualquier caso, hay que considerar que los resultados obtenidos son siempre previsiones, con base más o menos sólida, pero en general con cierto margen de error.

El planificador puede hacer uso de los diversos procedimientos de cálculo de espacios existentes para lograr una estimación del área requerida por cada actividad. Los datos obtenidos deben confrontarse con la disponibilidad real de espacio. Si la necesidad de espacio es mayor que la disponibilidad, deben realizarse los reajustes necesarios; bien disminuir la previsión de requerimiento de superficie de las actividades, o bien, aumentar la superficie total disponible modificando el proyecto de edificación (o el propio edificio si éste ya existe). El ajuste de las necesidades y disponibilidades de espacio suele ser un proceso iterativo de continuos acuerdos, correcciones y reajustes, que desemboca finalmente en una solución que se representa en el llamado *Diagrama relacional de espacios*.

El *Diagrama relacional de espacios* es similar a los diagramas relacionales presentados previamente (de actividades y de recorridos), con la particularidad de que en este caso los símbolos distintivos de cada actividad son representados a escala, de forma que el tamaño que ocupa cada uno sea proporcional al área necesaria para el desarrollo de la actividad (Figura 2.17). En estos símbolos es frecuente añadir, además, otro tipo de información referente a la actividad como, por ejemplo, el número de equipos o la planta en la que debe situarse.

Con la información incluida en este diagrama se está en disposición de construir un conjunto de distribuciones alternativas que den solución al problema. Se trata pues de transformar el diagrama *ideal* en una serie de distribuciones *reales*, considerando todos los factores condicionantes y limitaciones prácticas que afectan al problema. Como se indica en la Figura 2.13, el *systematic layout planning* finaliza con la implantación de la mejor alternativa tras un proceso de evaluación y selección. El planificador puede optar por diversas formas de generación de layouts (desde las meramente manuales hasta las más complejas técnicas metaheurísticas), y de evaluación de los mismos.




Figura 2.17: Diagrama relacional de espacios con indicación del área requerida por cada actividad.

## 2.6. Medición de la distancia y de la forma

Antes de abordar las técnicas presentadas en la bibliografía para la resolución del problema de la distribución en la planta de las diferentes actividades, se hace necesario determinar la forma en la que se medirá la distancia entre ellas una vez ubicadas, y la forma de las áreas asignadas a cada actividad. La mayor parte de los criterios empleados para la evaluación de la calidad de una solución determinada, utiliza la distancia entre las diferentes actividades de una forma u otra.

Por ejemplo, es muy habitual emplear el sumatorio del flujo entre cada par de actividades multiplicado por la distancia entre ellas. Por otra parte, para poder establecer cualquier tipo de restricción geométrica al área asignada a cada actividad es necesario poseer una manera de medir dicha forma.

### 2.6.1 Métricas de distancia

En algunos planteamientos las funciones evaluadoras miden únicamente la adyacencia entre actividades; es decir, que las actividades que así lo requieran posean una frontera común, aunque lo más habitual es medir si la disposición de las actividades es adecuada en base a la distancia a las que han sido ubicadas.

Aunque hay otras posibilidades, las métricas más frecuentemente empleadas miden la distancia entre los centroides de las áreas asignadas a las actividades. Ésta es una simplificación debida a que la localización de los puntos de recepción y expedición de materiales en cada actividad, son desconocidos hasta que no se determine el layout detallado y escogidos los sistemas de transporte de materiales. Así pues, el centroide representa en estos modelos tanto el punto de recepción como el de expedición del flujo de materiales interdepartamental.

Un problema de la utilización del centro geométrico de las áreas de las actividades como origen y final de las mediciones, es que hace necesario el empleo de mecanismos que eviten disposiciones *en diana* o excesivamente esbeltas de las actividades (Figura 2.18) que, aunque minimizan la distancia entre los centroides, no son operativas en la práctica.




Figura 2.18: Disposiciones que minimizan las distancia entre centroides de las áreas de las actividades.

Las métricas más extendidas son de tipo Minkowski, en las que la distancia n-dimensional entre dos actividades *i* y *j* se determina de la forma:

$$d_{ij}(p) = \sqrt[p]{\sum_{k=1}^n |x_{ik} - x_{jk}|^p}$$

haciendo variar *p* entre 1 e infinito obtenemos los diferentes tipos de métricas.

En [Heragu, 97] y en [Tompkins et al., 03] se enumeran las métricas más comunes; éstas son, para los centroides de dos actividades (*x<sub>i</sub>*, *y<sub>i</sub>*) y (*x<sub>j</sub>*, *y<sub>j</sub>*):

**Euclídea:** es una métrica Minkowsky con  $p=2$ , igual a la longitud de un segmento rectilíneo que une los centroides de las actividades. Su fórmula es, para dos dimensiones:

$$d_{ij} = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2}$$

**Euclídea cuadrática:** esta métrica, similar a la Euclídea, atribuye un mayor peso a aquellas actividades que se encuentran muy alejadas. No sigue el esquema Minkowsky y su formulación es:

$$d_{ij} = (x_i - x_j)^2 + (y_i - y_j)^2$$

**Manhattan:** También denominada rectangular o rectilínea, es una métrica Minkowsky con  $p=1$ . Representa la suma de las distancias vertical y horizontal entre los centroides de las actividades. Se expresa como:

$$d_{ij} = |x_i - x_j| + |y_i - y_j|$$

**Tchebychev:** Métrica Minkowsky con  $p=\infty$ , que considera la distancia como la mayor de las distancias (vertical u horizontal) entre los centroides de las actividades:

$$d_{ij} = \max(|x_i - x_j|, |y_i - y_j|)$$

**Contorno lateral:** Se calcula como el recorrido que debe realizar el material entre dos actividades a lo largo de pasillos que rodean las actividades existentes entre las dos consideradas. En la Figura 2.19 se calcularía como la suma de las longitudes de los segmentos azules. Aunque pueden emplearse los centroides de las actividades como inicio y final del recorrido, es habitual la definición de puntos de entrada y salida de materiales para calcular el contorno lateral.

**Adyacencia:** Es la métrica más sencilla, que únicamente distingue si las actividades comparten alguno de sus lados. Es empleada habitualmente con criterios cualitativos que estiman la

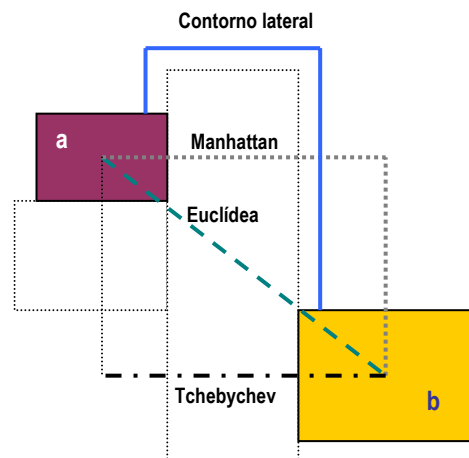


Figura 2.19: Métricas de distancia entre actividades. Ampliado de [Shebanie, 02].

conveniencia o no de que dos actividades sean adyacentes

$$d_{ij} = \begin{cases} 0 & ; \text{si las actividades } i \text{ y } j \text{ son adyacentes} \\ 1 & ; \text{en caso contrario} \end{cases}$$

**Camino más corto:** Esta métrica se emplea en planteamientos de resolución basados en teoría de grafos. Existen habitualmente varios caminos entre dos nodos del grafo cuyas longitudes, costes o tiempos de transporte vienen representadas mediante pesos. Esta métrica permite seleccionar el más corto.

La selección de una métrica u otra depende del sistema de transporte de materiales que se empleará [Heragu, 97; Tompkins et al., 03]. Por ejemplo, la utilización de un puente grúa de motores independientes en dos direcciones, se modelizará adecuadamente mediante la métrica de Tchebychev. El tiempo de transporte entre dos actividades será el que se tarde en recorrer la componente más larga (horizontal o vertical) del vector que une ambas actividades. Para carretillas o vehículos autoguiados, que deben desplazarse por pasillos que rodean los diferentes departamentos, el contorno lateral o la Manhattan serán las métricas más apropiadas. Las cintas transportadoras se modelizan mediante métricas Euclídeas.

La selección de una única métrica para medir la distancia entre todas las actividades en un problema puede considerarse una simplificación excesiva, dado que lo habitual es que un mismo proceso productivo necesite emplear diferentes sistemas de manutención. Algunas propuestas, como la de [Ozdemir et al., 03], introducen métricas heterogéneas dentro de un mismo problema.

Además de las métricas de uso habitual ya expuestas, algunos autores proponen otras más elaboradas, como es el caso de la distancia rectilínea esperada (EDIST) [Bozer et al., 97] o estudian el problema de la definición de los puntos de expedición o recepción, y el flujo de materiales intradepartamental: [Benson et al., 97; Chittratanawat et al., 99; Kim et al., 00; Arapoglu et al., 01; Shebanie, 02].

## 2.6.2 Medición de la forma

El establecimiento de restricciones de tipo geométrico a las actividades en los problemas multiárea, requiere definir maneras de evaluar la calidad de la forma de los departamentos a los que son asignadas. En la bibliografía es posible encontrar diferentes formas de medir la calidad formal de las soluciones, que en general se basan en la premisa de que es deseable que la forma de los departamentos sea lo más rectangular posible.

La mayor parte de los indicadores de calidad formal localizados en la bibliografía están dirigidos a un planteamiento discreto del problema, en el que las áreas de las actividades pueden adoptar formas más complejas e incluso desagregadas (separadas en áreas inconexas) que en los modelos continuos, en los que las áreas son, de manera general, rectangulares. El control de la desagregación será tratado posteriormente en el apartado 2.7.1.3.2.

En [Raoot et al., 93b] y en [Bozer et al., 94] se proponen indicadores de la calidad formal de las actividades ampliamente usados posteriormente. El primero de ellos parte del hecho de que dada una superficie con un área determinada, un mayor perímetro del área implica una mayor irregularidad de la forma. El menor perímetro corresponderá a la forma cuadrada; es decir, para una actividad  $i$  de área  $A_i$ , el perímetro será:

$$P_i^* = 4 \sqrt{A_i}$$

Si se considera ésta la forma óptima de la actividad, puede definirse un indicador normalizado ( $\Omega_1$ ) del grado de alejamiento del área asignada a una actividad de dicho óptimo, que se expresa como:

$$\Omega_1 = \frac{\frac{P_i}{A_i}}{\frac{P_i^*}{A_i}} = \frac{P_i}{P_i^*} = \frac{P_i}{4 \sqrt{A_i}}$$

Otro criterio propuesto es la *compacidad* ( $\Omega_2$ ), que trata de medir la desviación de la forma de una actividad respecto de un rectángulo. Se define como:

$$\Omega_2 = \frac{A_i}{A_{r\_i}}$$

donde  $A_i$  es el área de la actividad  $i$ , y  $A_{r\_i}$  es el área del rectángulo de menor área en el que puede inscribirse la actividad  $A_i$  dada su forma.

El tercer indicador ( $\Omega_3$ ) de la calidad formal del área de la actividad su calcula como el cociente entre el lado menor ( $l_{min}$ ) y el lado mayor ( $l_{max}$ ) del menor rectángulo en que puede inscribirse la actividad.

$$\Omega_3 = \frac{l_{min}}{l_{max}}$$

Por último, la calidad formal puede medirse mediante un símil con el momento de inercia de un cuerpo. Si se supone que la superficie asignada a la actividad tiene una densidad constante, puede calcularse su momento de inercia respecto al centro de gravedad. Así pues, para una actividad distribuida en  $n$  celdas, siendo  $m_i$  la masa asociada a la celda  $i$  y  $d_i$  la distancia de la celda  $i$  al centro de gravedad de la actividad, la expresión del indicador es:

$$\Omega_4 = \sum_{i=1}^{n_i} m_i d_i^2$$




Figura 2.20: Cálculo de la compacidad de actividades

## 2.7. Clasificación de las técnicas para la resolución del problema

La *teoría de la complejidad* estudia la dificultad intrínseca de la resolución de los problemas de optimización y decisión [Garey et al., 79]. Según dicha teoría, resolver una instancia de un problema<sup>8</sup> es obtener el valor óptimo de la función objetivo, es decir, se resuelve únicamente si se encuentra dicho valor y no una aproximación al mismo. Esta teoría clasifica los problemas en diversas categorías en función del número máximo de pasos que necesitaría un ordenador para la resolución; algunas de estas categorías o clases son:

La **Clase P**, que incluye a los problemas para los que existe un algoritmo de resolución tal, que el número de pasos de cálculo que requiere se puede expresar mediante una función polinomial del tamaño del problema y; la **Clase NP** que incluye aquellos problemas para los que no se conoce un algoritmo de resolución en tiempo polinómico, pero que pueden ser resueltos en dicho tiempo si se emplea un proceso de ilimitadas búsquedas paralelas independientes (mediante una computadora no determinista). De otra manera, la clase NP contiene todos los problemas para los que puede determinarse si una solución concreta es factible o no (problema de decisión), mediante un algoritmo en el que el número de pasos de cálculo se puede expresar mediante una función polinomial. La clase NP incluye a la clase P.

Un problema se denomina **NP-duro**, si cualquier problema de la clase NP se puede transformar en dicho problema. Un problema es **NP-completo** si es de clase P y NP-duro. Los problemas NP-completos tienen la propiedad de que cualquier problema de NP puede ser reducido a él en tiempo polinómico. Esto, y que a este tipo de problemas pertenezcan algunos clásicos (como el Circuito Hamiltoniano o el Problema del Viajante) para los que no se ha encontrado algoritmos de resolución en tiempos polinomiales, hace asumir que los problemas NP-completos son los más difíciles de resolver, y que con toda probabilidad necesiten tiempos de cálculo expresados mediante funciones exponenciales del tamaño del problema (clase EXP).

La Teoría de la complejidad sugiere, pues, que para los problemas NP-completos, a los que pertenece el que se trata en la presente tesis, no existe un algoritmo que proporcione una solución óptima en un tiempo razonable. Esto, unido a que el esfuerzo para comprobar la validez de una solución en un problema de este estilo no es muy elevado, ha provocado que la tendencia en los métodos de resolución evolucionara desde las técnicas enumerativas o exactas, hacia procedimientos heurísticos que proporcionan soluciones aceptables en tiempos de cálculo realistas.

Desde la década de los 50 del pasado siglo, y a partir de la formulación del problema planteado como del tipo cuadrático de asignación [Koopmans et al., 57], han sido muchas las técnicas y métodos elaborados para su resolución, con mayor o menor aproximación a la aplicabilidad inmediata de los resultados y con enfoques más o menos cercanos al carácter práctico y multicriterio del problema. Como resultado, existe un amplio abanico de propuestas que enfocan el problema con diferentes estrategias de construcción o mejora, formas diversas de evaluar las soluciones, o que emplean procedimientos basados en distintas analogías naturales. Determinadas publicaciones han supuesto una contribución

---

<sup>8</sup> La palabra "problema" se asocia a una descripción genérica de un problema, mientras que el término "instancia" se aplica a un problema en el que se han especificado todos los datos exactamente.



fundamental al problema abriendo nuevas vías de solución. Otras propuestas son variantes y mejoras de los procedimientos anteriores que, en conjunto, forman una gran batería de herramientas a disposición del planificador.

En principio las técnicas enumerativas o semi-enumerativas eran las predominantes en el intento de obtener soluciones óptimas. Posteriormente, y ante la complejidad del problema aparecerán y prevalecerán hasta la actualidad los métodos heurísticos. La clasificación de las técnicas para la resolución de este problema puede abordarse bajo distintos criterios, y en la bibliografía es posible encontrar abundantes recopilaciones de métodos (por ejemplo: [Rosenblatt, 79; Kusiack et al., 87] para el problema de layout específicamente, y [Stützle et al., 01; Loiola et al., 04] centradas en el problema cuadrático de asignación). En general, las taxonomías más abundantes se realizan por la forma de generar las diferentes soluciones, por la técnica empleada para la colocación de las actividades en sus posiciones o por la naturaleza de la técnica empleada para resolver el problema [Santamarina, 95; González-Cruz, 01; Ontiveros, 05]. Otras clasificaciones posibles son: la realizada en función del empleo de funciones objetivo que consideren criterios cualitativos, cuantitativos o de ambos tipos, del carácter multicriterio o no del método [González-García, 05], o de la dimensionalidad del dominio de ubicación (modelos meramente topológicos, lineales, bidimensionales o tridimensionales con la consideración de varias alturas de planta [Heragu, 97]).

En el presente trabajo se presentará una doble clasificación siguiendo la línea de [Santamarina, 95]. Estas clasificaciones se realizarán:

- por el modelo espacial empleado para situar las actividades en el dominio de ubicación, y
- por la técnica empleada para solucionar el problema.

### **2.7.1 Clasificación de las técnicas por el modelo espacial empleado para situar las actividades en el dominio de ubicación**

Dar solución a un problema de distribución en planta implica definir la situación de las diferentes actividades en el dominio de ubicación. La definición de la situación de cada actividad puede ser más o menos precisa, sus formas más o menos compactas o disgregadas, el dominio de definición puede ser constar de una única planta o de varias...; en definitiva, existen diferentes modelos geométricos y las técnicas de resolución del problema de distribución pueden clasificarse en función de cuál adoptan.

Como se indica en [González-García, 05] una posible clasificación dividiría las técnicas en dos grandes grupos según adopten dos tipos de modelos: los modelos topológicos y los modelos geométricos. Los modelos geométricos a su vez pueden clasificarse según la dimensionalidad del dominio de ubicación en unidimensionales, bidimensionales, multiplanta y tridimensionales (Figura 2.21). Los modelos bidimensionales y multiplanta pueden dividirse, además, según que el problema se formule discretizando el dominio global en pequeñas unidades de área, o que el espacio asignado a cada actividad se determine mediante cortes recursivos del dominio. Al primer tipo se le denomina modelo discreto y al segundo modelo continuo. A estos dos habría que añadir un tercer tipo de modelo que emplea técnicas

analíticas para la colocación de las actividades.

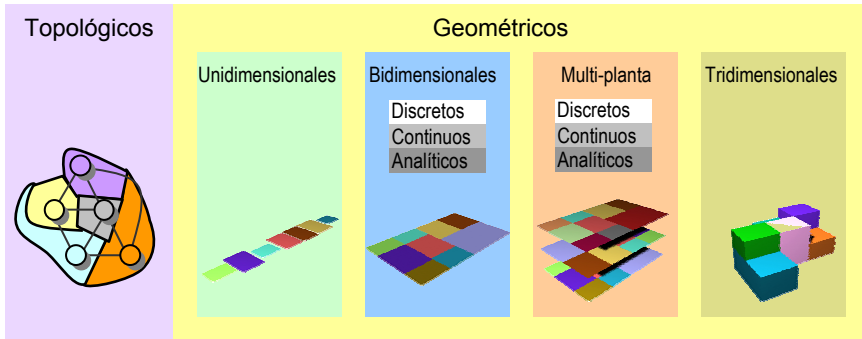


Figura 2.21: Clasificación de los modelos espaciales empleados por las técnicas de resolución del problema de distribución en planta.

### 2.7.1.1 Modelos topológicos

Los modelos topológicos no proporcionan una definición exacta de la distribución de las actividades sino, más bien, una estructura topológica (generalmente representada mediante un diagrama) que considere las relaciones de las actividades. El diagrama topológico de actividades representará una disposición aproximada de las mismas, de manera que se logre evitar los cruzamientos de los recorridos entre ellas, hacer adyacentes aquellas que con más intensidad se relacionan, separar aquellas que lo requieran y, en definitiva, hacer cumplir los principios de la distribución en planta (Figura 2.22). En ningún caso se considera el área o la forma de la superficie requerida por las actividades. El paradigma de modelo topológico se da en las técnicas basadas en la Teoría de Grafos.




Figura 2.22: Diagrama topológico de actividades.

#### 2.7.1.1.1 Teoría de grafos

La primera aplicación sistemática de la teoría de grafos al problema de la distribución en planta la realizan Seppanen y Moore en 1970 [Seppanen et al., 70] (se realizaron algunas aproximaciones previas en [Buffa, 55] y [Levin, 64]). Para conocer más profundamente los fundamentos del procedimiento y una revisión de métodos que lo aplican puede consultarse [Hassan et al., 87]. En general, estos procedimientos no logran asegurar que los

departamentos con relaciones más intensas permanezcan adyacentes [Hassan et al., 87], y las formas de las actividades obtenidas suelen ser irregulares y de baja calidad geométrica.

En la aplicación de la teoría de grafos a la resolución del problema de distribución pueden distinguirse tres etapas:

**Primera etapa:** El diagrama relacional de recorridos y/o actividades [Muther, 68], generado mediante la tabla relacional de actividades, se transforma en un *grafo planar ponderado maximal*. Se dice que un grafo es *ponderado* si a sus aristas se les asocian valores (pesos) que pueden ser empleados como representación de magnitudes (por ejemplo coste o beneficio). Se dice que un grafo es *planar* si es posible representarlo bidimensionalmente de manera que sus aristas se intersecten sólo en los vértices. Se dice que un grafo planar es *planar maximal* si deja de serlo en caso de que se le añada una arista más. Con todo esto, un *grafo planar ponderado maximal* es un grafo planar maximal cuyas aristas tienen los mayores pesos asociados posibles.

En esta primera etapa se considera a las actividades carentes de área, primando en el estudio las relaciones entre actividades sobre la geometría y área de las mismas. Los nodos del grafo representan las actividades, y las aristas con sus pesos asociados las intensidades relacionales entre actividades. Dado que para formar un grafo planar el número de aristas que unen los nodos es limitado<sup>9</sup> sólo se mantienen aquellas relaciones de mayor intensidad.

En la Figura 2.23 se representa un diagrama relacional de 5 actividades. El número máximo de aristas que podría tener un grafo planar de 5 vértices es 9 (3·5-6). En la construcción del grafo planar se ha añadido un vértice que representa el exterior de la planta y se ha unido con los vértices exteriores del grafo.




Figura 2.23: Generación de un grafo planar ponderado maximal a partir de un diagrama relacional. Adaptado de [Santamarina, 95].

Para el apoyo a la generación del grafo planar ponderado maximal existen métodos que es posible clasificar en dos grupos: los que verifican la condición de planaridad tras la adición de una nueva arista, y los que evitan tener que realizar la verificación mediante una serie de premisas en el método constructivo empleado. Dentro del primer tipo destacan: el algoritmo

<sup>9</sup> Para respetar la condición de planaridad el número máximo de aristas de un grafo de  $n$  vértices es  $3n-6$ .

presentado en [Carrie et al., 78] que emplea un árbol de expansión maximal, o el de Foulds [Foulds et al., 76] que hace uso de algoritmos de tipo *branch and bound*. Dentro del segundo tipo en [Moore, 76] se emplea una representación del grafo mediante una cadena de símbolos, en [Foulds et al., 78] se propone un método constructivo basado en la creación progresiva de caras triangulares, en [Green et al., 85] se desarrolla un algoritmo de tipo heurístico y una representación matricial del grafo. Destacables también son los algoritmos GASOL [Hammouche et al., 85] y TESSA [Boswell, 92].

**Segunda etapa:** A partir del grafo planar ponderado maximal se construye el *grafo dual*. El procedimiento consiste en colocar un vértice en cada cara del grafo planar y conectar con una arista los diferentes pares de vértices cuyas caras tienen arista común. De esta manera se obtiene un nuevo grafo denominado *grafo dual* del original. Considerando ambos grafos de manera conjunta se aprecia que cada vértice del grafo original (actividad) queda rodeado por las aristas del grafo dual, intuyéndose ya un posible layout (sin control formal de ningún tipo). En la Figura 2.24 puede apreciarse que se ha introducido un vértice ficticio exterior en el grafo dual (el 8), necesario para que todas las actividades del grafo queden inscritas entre las aristas del grafo dual.

**Tercera etapa:** En esta última etapa se consideran por fin los aspectos geométricos del problema (área y forma). A partir del grafo dual se debe obtener una distribución representada por un diagrama de bloques o layout de bloques. Este proceso no es sistemático, necesitando de continuos ajustes de las diferentes soluciones que es posible obtener de un mismo grafo dual (Figura 2.25). Los algoritmos desarrollados para esta etapa son menos abundantes que los dirigidos a generar el gráfico planar ponderado maximal, y entre ellos cabe destacar los propuestos por Hassan y Hogg [Hassan et al., 89; Hassan et al., 91] que emplean algoritmos constructivos similares a los clásicos ALDEP o CORELAP.

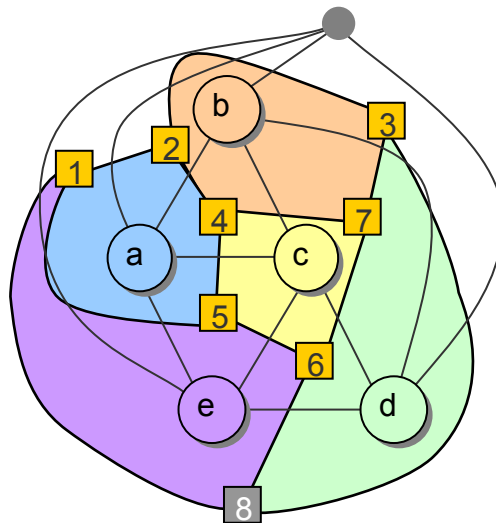


Figura 2.24: Construcción de un grafo dual e introducción de una actividad exterior ficticia). Adaptado de [Santamarina, 95].




Figura 2.25: Transformación del grafo dual en un layout de bloques. Adaptado de [Santamarina, 95]

### 2.7.1.2 Modelos geométricos

La mayor parte de las técnicas de resolución del problema de distribución emplean este tipo de modelos en la ubicación de las actividades. Los modelos geométricos consideran que las actividades no son simples entelequias adimensionales, sino que se les debe asignar una superficie con un área mínima y con ciertas restricciones en cuanto a la forma.




Figura 2.26: Modelos geométricos (a) unidimensionales, (b) bidimensionales, (c) multiplanta y (d) tridimensionales.

Los modelos geométricos pueden ser clasificados (como propone [González-García, 05]) en función de la dimensionalidad del dominio de ubicación. Según esta clasificación los modelos pueden ser unidimensionales, bidimensionales, multi-planta y tridimensionales.

Los modelos **unidimensionales** plantean el problema como la secuenciación de las actividades en una única alineación (Figura 2.26 a) o en varias líneas paralelas, lo cual corresponde a una disposición que se da con cierta frecuencia en la realidad. Las actividades poseen áreas diferentes y en la evaluación se considera el flujo de materiales entre ellas. Modelos de este estilo se emplean en [Simmons, 69] y en [González-Cruz, 01]. En el primer caso se utiliza un algoritmo *branch and bound* en la resolución y no se considera ningún tipo de restricción en cuanto a la colocación de determinadas actividades a posiciones concretas. En el caso de González-Cruz, la resolución del problema se realiza mediante un método derivado de una estrategia de resolución de problemas basada en la Teoría de las Dimensiones del Proyecto [Gómez-Senent et al., 97].

En [Heragu et al., 92] se propone un algoritmo basado en recocido simulado que obtuvo soluciones óptimas para 6 de 8 problemas de test de una sola línea, mejorando las soluciones conocidas para los dos restantes. Este mismo algoritmo logró muy buenos resultados en problemas multi-línea, incluidos algunos de los conocidos problemas de Nugent [Nugent et al., 68].

Los modelos **bidimensionales** son aquellos en los que el dominio de ubicación sobre el que se sitúan las actividades es una única superficie plana (Figura 2.26 b). La mayor parte de los métodos descritos en la bibliografía emplean modelos bidimensionales. Dado que el presente trabajo se centra en este tipo de modelos, se realizará una amplia descripción de métodos que lo emplean en apartados posteriores.

El modelo **multi-planta** (multi-floor) considera el dominio de ubicación como varias superficies a distintos niveles, es decir, como varias plantas de un mismo edificio (Figura 2.26 c). Una revisión de métodos que emplean este modelo puede encontrarse en [Meller et al., 97]. En algunos casos se trata adaptaciones de los métodos bidimensionales, en los que se introduce una fase previa de selección de la planta en la que se ubicará cada actividad (métodos en dos fases). Los métodos en una fase, al contrario, permiten que las actividades varíen la planta a la que son asignadas durante la ejecución del algoritmo. Al primer tipo pertenece el método HGA [Lin et al., 00] en el que tras haber seleccionado la planta de cada actividad, un algoritmo genético distribuye las actividades dentro de sus niveles correspondientes. El método ALDEP puede ser empleado con modelos multi-planta como indican sus autores en el mismo artículo en el que definen el método [Seehof et al., 67], sin embargo, en éste no queda muy claro como se realiza la asignación de las actividades a las plantas, y se ignora el tráfico de materiales entre los diferentes niveles durante la evaluación. SPS [Liggett et al., 81], plantea la primera fase de asignación de actividades a plantas como un problema cuadrático de asignación y lo resuelve mediante procedimientos heurísticos. Este método permite que el área asignada a una actividad esté dividida en diferentes plantas. En la segunda fase se emplea de nuevo una formulación como problema cuadrático de asignación para determinar el layout de cada planta de forma independiente.

SPACECRAFT [Johnson, 82] es un método en una fase derivado de otro que emplea modelos bidimensionales, en este caso el CRAFT. SPACECRAFT es un método de mejora basado en el intercambio de la posición de actividades adyacentes o de igual tamaño a partir

de una solución inicial. En este caso se considera el costo del movimiento de los materiales entre las diferentes plantas, sin embargo, las actividades pueden ser divididas en distintos niveles, y los intercambios de actividades están limitados a aquellos que involucran actividades adyacentes o de igual área.

Este último problema es solventado por otros métodos empleando *curvas de llenado de espacios* (llamadas en inglés *Spacefilling Curves* y que serán tratadas más adelante) para la colocación de las actividades. Entre ellos MULTIPLE [Bozer et al., 94], basado en CRAFT, introduce el control de forma de los departamentos y permite el intercambio de cualquier par de actividades, incluso entre plantas diferentes, sin permitir que una actividad quede distribuida en dos niveles. SABLE [Meller et al., 96a] algoritmo en una única fase, emplea también curvas de llenado de espacios para colocar las actividades y logra generalizar el intercambio de actividades. Genera una solución inicial mediante una lista de candidatos a entrar en la distribución que va asignando a los diferentes niveles. La solución inicial es mejorada con intercambios de departamentos. Meller y Bozer, los autores de MULTIPLE y SABLE, crearon STAGES y FLEX [Meller et al., 97], procedimientos en dos fases que emplean curvas de llenado de espacios.

Otras propuestas destacables en el ámbito de la distribución multi-planta son MULTI-HOPE [Kochhar et al., 98] que discretiza el recinto en trozos iguales de una determinada área y asigna a cada actividad el número de trozos necesarios para albergarla, y la presentada en [Lee et al., 05], que emplea un algoritmo genético que representa las soluciones mediante cromosomas con cinco segmentos. Las relaciones entre las instalaciones, corredores y elevadores son representados mediante un gráfico de adyacencia.

Los métodos multi-planta presentados hasta el momento emplean técnicas discretas. Existen otros métodos basados en modelos continuos de división del dominio de ubicación como por ejemplo LOGIC [Tam, 92a] y MUSE [Matsuzaki et al., 05], algoritmos basados en árboles de corte que permiten obtener formas rectangulares para las actividades. La forma de actuación de las técnicas que emplean modelos discretos, continuos o analíticos será tratada en los siguientes apartados.

Por último, los modelos geométricos **tridimensionales** son los menos presentes en la bibliografía. Consideran el dominio de ubicación como tridimensional (Figura 2.26 c). Como ejemplo, un método que emplea este modelo es el expuesto en [Barbosa-Povoa et al., 02].

### 2.7.1.3 Modelos discretos

Como se ha indicado en apartados precedentes, los modelos bidimensionales y multi-planta, pueden subdividirse a su vez en modelos discretos, continuos y analíticos. Las técnicas que formulan el problema de la distribución en planta bajo modelos discretos, parten de una subdivisión del dominio de ubicación en una retícula de subdominios de igual área. Las actividades serán situadas en el dominio asignándoles el número suficiente de subdominios para cubrir sus necesidades espaciales.

El problema puede plantearse de la siguiente manera:

*Dado un dominio  $D$ , de área conocida  $A$  y geometría conocida o desconocida, el problema consiste en ubicar en él, sin solapamiento,  $m$  actividades de área conocida  $a_i$  y*

geometría libre  $D_i(a_i)$ , entre las que existe una serie de relaciones que hacen preferible o no su cercanía.

Es necesario resaltar, que en este tipo de modelos las actividades no poseen restricciones formales, es decir, no se define a priori la forma, ni el ratio de aspecto ni algún otro tipo de limitación en cuanto a geometría.

El dominio se *discretiza* dividiéndolo en una retícula de  $m$  subdominios elementales de área  $a$ , cumpliéndose que  $A = m \cdot a$ , produciéndose la siguiente transformación:

$$D(A) \rightarrow D(n, a)$$

$$D_i(a_i) \rightarrow D_i(n_i, a) / a_i = n_i \cdot a$$

Así pues, el dominio se transforma en un conjunto de  $n$  ubicaciones a las que se debe asignar las  $m$  actividades. A cada actividad  $i$  se le asociará un conjunto de celdas  $S_i$  sobre las que se distribuirá, denominado *conjunto de asignación*. Dado que el dominio está discretizado, es posible establecer una *matriz de distancias* que recoja las distancias (medidas mediante la métrica que se establezca) que existe entre las diferentes casillas en que se ha dividido el dominio.




Figura 2.27: Ejemplo de solución obtenida mediante técnicas discretas.

Además es posible definir una variable de asignación  $x_{ik}$ , cuyo valor será 1 si la actividad  $i$  ha sido asignada a la ubicación  $k$ , y que valdrá 0 en caso de que no sea así. Con el conjunto de estos valores puede formarse la *matriz de asignación*, que contiene la información referente a la posición ocupada por cada actividad.

A partir de la *matriz de distancias* que indica la distancia entre ubicaciones, la *matriz de asignación* que indica la ubicación de cada actividad, y la necesidad de cercanía o lejanía de las actividades, es posible evaluar la calidad de cada una de las posibles configuraciones del sistema (soluciones). El objetivo perseguido es localizar aquella configuración del sistema, representada por la *matriz de asignación*, que optimice la función objetivo bajo los diferentes criterios que se establezcan.

A la formulación del problema deben añadirse las restricciones necesarias, por ejemplo: que el número de subdominios asignados a cada actividad sea suficiente para cubrir sus necesidades de espacio, que no exista superposición, es decir, que una misma casilla no esté asignada a más de una actividad, y las restricciones geométricas necesarias, entre las que es fundamental la de no disgregación de las actividades, es decir, que una actividad sea asignada a celdas contiguas.



La mayor parte de los métodos bidimensionales y multi-planta emplean el modelo discreto, por ejemplo: CRAFT [ Armour et al., 63], CORELAP [ Lee et al., 67], ALDEP [ Seehof et al., 67], PLANET [ Apple et al., 72], MULTIPLE [ Bozer et al., 94] o SABLE [ Meller et al., 96a], así como muchos de los métodos basados en metaheurísticas.

### 2.7.1.3.1 Curvas de llenado de espacios

Como se ha indicado al tratar el tema de los modelos multiplanta, muchos de los métodos de resolución que emplean modelos discretos, como MULTIPLE o SABLE, usan las llamadas *Spacefilling Curves* para asignar las actividades a los diferentes subdominios. El proceso consiste en determinar, por algún procedimiento, la secuencia en la que las actividades serán introducidas en el dominio. Una vez obtenida dicha secuencia, éstas son colocadas en el dominio siguiendo el recorrido marcado por la curva de llenado de espacios. La curva recorre el dominio asignando tantos subdominios a las actividades como requieran (Figura 2.28 a). Una vez que se ha colocado la primera actividad se sitúa la siguiente de la secuencia ocupando los subdominios necesarios. Este proceso continúa hasta finalizar la secuencia. Generar un nuevo layout es tan sencillo como variar el orden de la secuencia de introducción de las actividades (Figura 2.28 b). En [Bozer et al., 94] puede encontrarse un análisis del impacto de la forma de las curvas de llenado de espacios sobre el layout

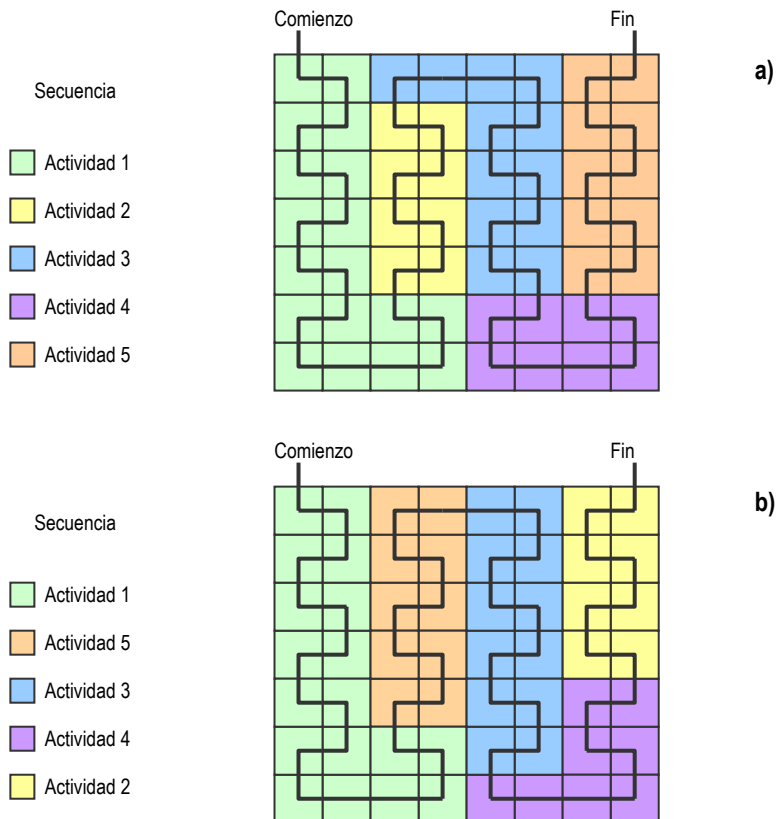


Figura 2.28: Curvas de llenado de espacios e intercambio de actividades en la secuencia de actividades.

generado.

### 2.7.1.3.2 El control de la agregación en los modelos discretos

La calidad formal de las soluciones encontradas por los diferentes algoritmos debe ser controlada, para que la forma asignada a las instalaciones satisfaga las necesidades de espacio de cada actividad. En general el área asignada será la necesaria para cada actividad, sin embargo la forma de dicho espacio puede hacer imposible la implementación de la solución. Existen diferentes formas de medir la calidad de la forma de las actividades de una determinada solución que serán tratadas más adelante.

En los modelos discretos puede ocurrir que el espacio asignado a una actividad esté desagregado, es decir, separado en dos o más zonas diferentes del dominio. En estos modelos debe implementarse algún mecanismo de control de la agregación. Entre estos modelos se cuentan el *algoritmo de etiquetado* y el *algoritmo de la matriz de conectividad*.

El primero es empleado fundamentalmente en el tratamiento de imágenes almacenadas como mapas de bits. Puede establecerse cierta analogía entre un mapa de bits y una distribución obtenida mediante un modelo discreto. Cada una de las celdas correspondería a uno de los píxeles que conforman la imagen y la actividad a la que pertenece dicha celda sería el color de dicho píxel. Para cada actividad de la que se quiera comprobar la integridad formal, se recorre celda a celda el dominio de arriba abajo y de izquierda a derecha, comprobando si las celdas aledañas a la actual pertenecen a la misma *actividad padre*, y etiquetando las celdas que pertenecen a dicha actividad. Finalizado el recorrido a cada celda de la actividad que se está analizando le corresponde una etiqueta y es posible establecer el número de fragmentos en que se ha disgregado la actividad. El segundo método emplea una matriz de valores binarios que indica la conectividad de cada una de las celdas de una actividad con las demás.

### 2.7.1.4 Modelos continuos

De manera general los modelos continuos construyen las diferentes distribuciones de las actividades en el dominio mediante el corte recursivo del mismo. Las técnicas que emplean modelos continuos suelen proporcionar un gran control de la geometría de las actividades y un elevado aprovechamiento del espacio de la planta evitando las áreas sin asignar. El planteamiento matemático es el siguiente:



Figura 2.29: Solución obtenida mediante técnicas de corte.

*Dado un dominio  $D$ , de área conocida  $A$  y geometría conocida, el problema consiste en ubicar en él, sin solapamiento,  $m$  actividades de área conocida  $a_i$  y geometría flexible  $D_i(a_i)$ , entre las que existe una serie de relaciones que hacen preferible o no su cercanía, de modo que la distribución sea óptima bajo los criterios establecidos para su evaluación.*

Las actividades tienen forma rectangular y geometría flexible, lo que significa que el ratio entre la altura y la anchura del área asignada a la actividad puede variar dentro de ciertos márgenes (restricciones geométricas). En la Figura 2.30 puede observarse las formas que puede adoptar una actividad de geometría flexible; el área de la actividad se mantiene mientras la relación entre el alto y el ancho de la actividad varía entre ciertos límites.




Figura 2.30: Actividad de geometría flexible.

Aunque existen otras formas de implementar los modelos continuos (como las matrices de localización [Kim et al., 98]), este trabajo se centrará en las más habituales, las que emplean árboles de corte (slicing trees) y los modelos de bahías flexibles (flexible bay).

#### 2.7.1.4.1 Árboles de corte

Los árboles de corte como forma de representación de la distribución en planta, aparecen en el inicio de la década de los 80 del siglo pasado tal y como se recoge en [Tam, 92a] y [Tam, 92c]. Dado que las distribuciones pueden construirse por cortes recursivos del dominio de ubicación, éstas pueden ser representadas como una secuencia o estructura de cortes. Cada partición rectangular en la estructura de cortes corresponde al espacio destinado a cada departamento. En general los cortes se realizan en dos direcciones habitualmente paralelas a los ejes del sistema de referencia fijado. Lo más común es emplear cortes verticales y horizontales, aunque es posible definir otros tipos como los cortes en "L" propuestos por Tam en [Tam, 92c].




Figura 2.31: Construcción de una distribución por cortes recursivos del dominio.

Así pues, para generar las soluciones se van realizando los cortes al dominio según las direcciones establecidas, quedando las diferentes actividades a un lado u otro del corte realizado. Para decidir qué actividades quedarán a cada lado debe realizarse previamente un proceso de agrupación de las mismas en función de sus afinidades. Realizar este agrupamiento de manera conveniente resulta fundamental dado que determinará de manera decisiva la distribución final de las actividades. Esta agrupación debe llevarse a cabo de manera que las actividades que lo requieran permanezcan adyacentes, o al menos cercanas, en la distribución final, y alejadas aquellas a las que les es preceptivo.

Por ejemplo, en la Figura 2.32, se realiza inicialmente un corte vertical que divide el dominio en dos subdominios. Las actividades que forman la distribución quedan a un lado u otro del corte en función de la agrupación que se haya hecho previamente de las mismas. El corte se lleva a cabo en una posición tal que deja suficiente espacio a ambos lados como para albergar las actividades correspondientes. Las actividades que quedan a cada lado del corte son posteriormente vueltas a separar por nuevos cortes hasta generar la distribución definitiva.




Figura 2.32: Generación de una distribución mediante sucesivos cortes del dominio de ubicación.

Para realizar la agrupación se pueden emplear diversas técnicas. Por ejemplo, en las primeras fases de las técnicas basadas en teoría de grafos, las agrupaciones topológicas son realizadas en función de las afinidades de las actividades (ver 2.7.1.1.1). El grafo planar ponderado maximal calculado es, precisamente, un intento de hacer adyacentes aquellas actividades con una mayor intensidad relacional.

Otra posibilidad es emplear un algoritmo metaheurístico en la búsqueda de la agrupación óptima. En el método LAYAGEN en dos fases presentado por Santamarina [Santamarina, 95], la primera de las fases es precisamente la búsqueda de la agrupación más conveniente de las actividades mediante un algoritmo genético. En [Tam et al., 98] es también un algoritmo genético el que busca la estructura de cortes más adecuada.

Las técnicas de agrupamiento (*clustering*) basadas en análisis multivariante son las más tradicionales. Las técnicas de *clustering* analizan la afinidad entre actividades evaluando la distancia existente entre ellas, y agrupándolas en función de dicha distancia. En este caso la distancia será una función inversa de la intensidad relacional, es decir, la distancia será menor cuanto mayor sea la intensidad relacional. Por ejemplo, Tam propone como medida de la distancia entre dos actividades  $i$  y  $j$ :

$$d_{ij} = \frac{1}{1 + w_{ij} + w_{ji}}$$

donde  $w_{ij}$  y  $w_{ji}$  es el flujo de materiales entre las actividades. Con estas distancias es posible formar un *matriz de distancias*  $D$ , que representa la distancia existente entre cada par de actividades.

Una vez establecidas las distancias se procede al agrupamiento. En el caso de Tam, procede agrupando inicialmente las dos actividades más cercanas entre sí. Tras ello el grupo formado pasa a ser considerado como una actividad, recalculándose su distancia a cada una de las actividades restantes y modificando en consecuencia la matriz de distancias. El procedimiento continúa agrupando de nuevo aquellas actividades/grupos más cercanos entre sí.

Para un problema de  $n$  actividades, deberán realizarse  $n-1$  agrupamientos. El recálculo de las distancias se llevará a cabo cada vez que se cree un grupo. Para calcular la distancia a un grupo de actividades existen diversas métricas: encadenamiento simple, encadenamiento completo, centroide, *group average*, etc. Tam emplea el *group average* como medida de la distancia entre cualquier actividad no agrupada,  $a$ , y un grupo,  $g$ , formado por la unión de dos elementos  $i$  y  $j$  que pueden ser actividades o *clusters* ya formados. La nueva distancia se calcula como:

$$d_{a(ij)}^2 = \frac{n_i}{n_i + n_j} d_{ai}^2 + \frac{n_j}{n_i + n_j} d_{aj}^2$$

donde:

$n_i$  es el número de actividades que conforman el grupo  $i$ ;

$n_j$  es el número de actividades que conforman el grupo  $j$ ;

$d_{ai}$  es la distancia entre la actividad  $a$  y la actividad o grupo de actividades  $i$  antes de la fusión y

$d_{aj}$  es la distancia entre la actividad  $a$  y la actividad o grupo de actividades  $j$  antes de la fusión.

El mostrado es el procedimiento empleado por Tam. Existe otro tipo de algoritmos de clustering que pueden clasificarse en función de la estrategia de agrupación. Los **aglomerativos** son aquellos que parten de un número determinado de clases o grupos individuales que van siendo fusionados para obtener grupos cada vez más poblados. Los **divisivos**, parten de un conjunto de clases o grupos que se van dividiendo en clases cada vez más pequeñas y numerosas. Otra posible clasificación es en función de los criterios empleados para realizar el agrupamiento o división. Así las técnicas **politéticas** deciden las fusiones o divisiones en función de un conjunto de caracteres o criterios, mientras que las **monotéticas** deciden en función de un solo criterio. Bajo esta perspectiva el modelo empleado por Tam sería aglomerativo monotético, dado que la distancia es medida únicamente bajo el prisma del flujo de materiales entre actividades.

Una forma clásica de representar las afinidades entre actividades es mediante un diagrama denominado *dendograma* que refleja las diferentes etapas seguidas durante el

proceso de agrupamiento (ver Figura 2.33).




Figura 2.33: Proceso de agrupamiento de actividades y dendograma representativo.

El dendograma resultante de la agrupación muestra el número de cortes a realizar y el lado del corte en el que debe quedar cada actividad tras el corte correspondiente. Por ejemplo, el dendograma de la Figura 2.33 indica que tras el primer corte, las actividades 1, 2 y 3 quedarán a un lado, mientras que la 4 y la 5 quedarán al otro.

Para poder generar la distribución a partir del dendograma es necesario añadir la información referente al modo en que se realizarán los cortes. Añadiendo dicha información al dendograma obtenemos un árbol de cortes (*slicing tree*). Un árbol de cortes es un árbol binario que representa el proceso de partición que genera la estructura de cortes. Cada nodo interno del árbol representa la forma en la que se realiza el corte, designado mediante una letra. Cada hoja del árbol (nodos extremos de los que no penden otros nodos) representa una actividad identificada mediante un número (Figura 2.34).

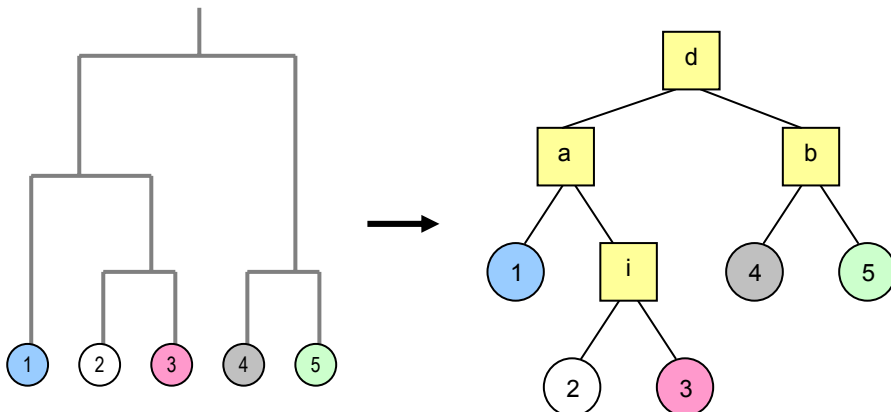


Figura 2.34: Dendograma + información de cortes → árbol de cortes.

Para distribuir  $n$  actividades es necesario realizar  $n-1$  cortes, por lo tanto el árbol de cortes correspondiente tendrá  $n$  hojas y  $n-1$  nodos internos. La topología del árbol dependerá de la forma en la que se han agrupado las actividades.

Ya se ha dicho que en los nodos internos se indica mediante una letra el tipo de corte ha realizar. A estos se les denomina *operadores de corte* y aunque algunos autores hacen otras propuestas, en general, se emplean los cuatro siguientes: corte vertical arriba, corte vertical abajo, corte horizontal izquierda y corte vertical derecha. Para simplificar, se les denomina *arriba*, *abajo*, *izquierda* y *derecha* respectivamente.

El operador *arriba* divide el subdominio correspondiente mediante un corte horizontal, situando las actividades que penden de la rama izquierda del nodo en cuestión en la parte superior del corte, y las que penden de la rama derecha en la parte inferior del corte. El operador *abajo* actúa mediante un corte horizontal, situando esta vez las actividades que penden de la rama izquierda del nodo en la parte inferior del corte, y las que penden de la rama derecha en la parte superior. *Izquierda* y *derecha* aplican cortes verticales, el primero sitúa las actividades del ramal izquierdo en la parte izquierda del corte y a la derecha los del ramal derecho, mientras que el operador *derecha* actúa a la inversa. La forma de operar queda resumida en la Figura 2.35. Los operadores de corte se codifican mediante letras del alfabeto para colocarlas en los nodos. En castellano se emplea el código:

**a:** arriba; **b:** abajo; **i:** izquierda; **d:** derecha

mientras que las siglas habituales en inglés son:

**u:** up; **b:** bottom; **l:** left; **r:** right

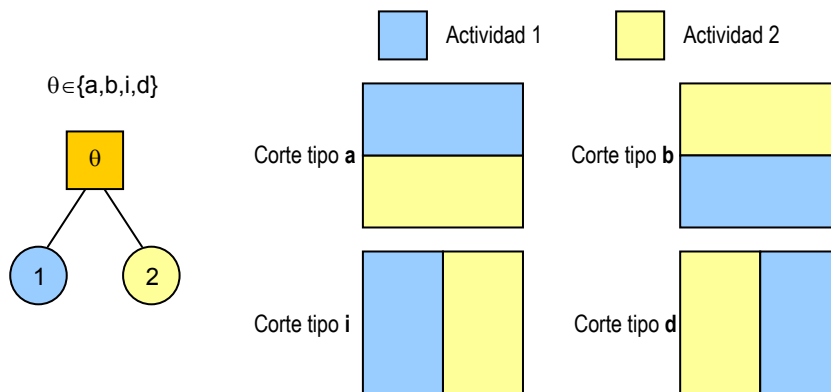


Figura 2.35: Resultado de la aplicación de los diferentes operadores de corte sobre un nodo.

Para componer una distribución a partir de un árbol de cortes dado se procede recorriendo el árbol y realizando los cortes indicados en los nodos, colocando las actividades en los lados correspondientes del corte. Por convención se realiza un recorrido *preorden* del árbol, aunque algunos autores lo proponen *postorden*. Un recorrido *preorden* es aquel en el que se parte del nodo raíz y se visita primero la rama izquierda. Una vez recorrida ésta se

continúa con la derecha. Al llegar a cualquier nodo se sigue el mismo criterio, visitando primero el subárbol izquierdo y después el derecho. Un recorrido de tipo *postorden* sigue el criterio opuesto. Otro tipo de recorridos puede consultarse en [Cohon et al., 91].

En la Figura 2.36 se ejemplifica un recorrido preorden. Se comienza por el nodo raíz marcado como 1 realizando el corte que se indique en dicho nodo. Se desciende hacia el nodo 2; se realiza el corte correspondiente y se visita la actividad que pende en su ramal izquierdo. Se retorna al nodo 2 y se desciende ahora al nodo 3 cortando de la forma que indique dicho nodo. Se recorren las actividades que penden de este nodo comenzando por la izquierda y continuando por la derecha. Tras esto se asciende de nuevo al nodo 3, de éste al 2 y al 1. Desde este punto se realiza el recorrido equivalente por el subárbol derecho.




Figura 2.36: Recorrido preorden de un árbol de cortes. Adaptado de [Santamarina, 95].

Al realizar cada corte se debe dejar suficiente espacio en cada subdominio generado como para que quepan las actividades correspondientes. En la Figura 2.37 se puede apreciar la construcción de una distribución mediante un recorrido postorden del árbol.




Figura 2.37: Generación de una distribución a partir de un árbol de cortes.



A partir de un mismo árbol de cortes es posible obtener gran cantidad de distribuciones diferentes. Para ello sólo es necesario variar los operadores de corte asignados a cada nodo. Concretamente, el número de configuraciones posibles para un árbol de  $m$  actividades es:

$$N = \left(\frac{p}{2}\right)^{m-1} m!(m-1)!$$

donde  $p$  es la cardinalidad del conjunto de operadores de corte. Por ejemplo, para la distribución de 10 actividades mediante los 4 operadores de corte habituales es posible obtener de un mismo árbol de cortes 6,742 e<sup>14</sup> configuraciones diferentes.

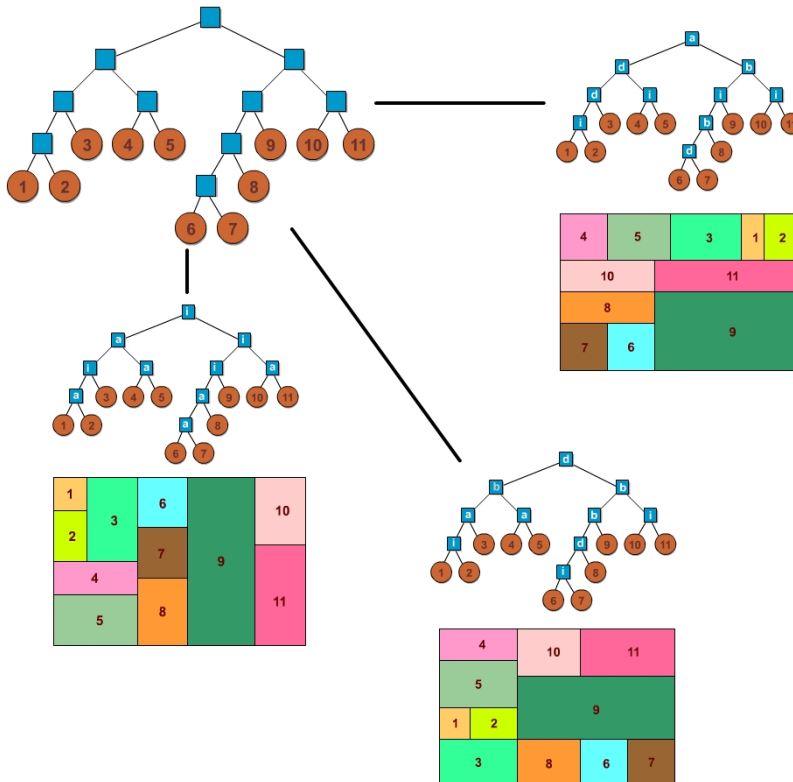


Figura 2.38: Obtención de diferentes distribuciones a partir de un árbol de cortes mediante la modificación de los operadores de corte.

#### 2.7.1.4.2 Estructuras de bahías flexibles

La generación de layouts mediante bahías flexibles [Tong, 91], permite la distribución de actividades rectangulares de área desigual en dominios habitualmente rectangulares. Este dominio es dividido en una dirección determinada en “bahías” de anchura variable. Dentro de cada una de estas bahías se coloca un número también variable de actividades que poseerán igual anchura, y altura proporcional al área requerida por cada una. La anchura de la bahía se adapta para acoger a las actividades que contiene (Figura 2.39). El término

*flexible* se refiere tanto a la anchura de las bahías como a su número, dado que éste también puede variar. Es habitual el empleo de heurísticas para la determinación del número de bahías y de la secuencia de actividades que se asignarán a cada bahía [Tate et al., 95; Coit et al., 96].

La formulación del problema mediante estructuras de bahías flexibles limita mucho el espacio de búsqueda de soluciones. Evidentemente sólo serán accesibles las soluciones que puedan ser representadas mediante dicha estructura. Por ejemplo, las soluciones al problema que se pueden obtener deben cumplir que todas las actividades asignadas a una bahía tengan la misma anchura. Como muestra, el espacio de soluciones del problema que es posible explorar mediante árboles de corte




Figura 2.39: Distribución obtenida mediante estructuras de bahía. Las 17 actividades se han distribuido en 5 bahías.

es más amplio que el abordable por bahías flexibles. De hecho, el segundo es un subconjunto del primero; cualquier solución expresable mediante bahías flexibles puede representarse mediante árboles de corte.

Concretamente, el número de configuraciones posibles para un problema de  $m$  actividades es:

$$N = 2^{m-3} m!$$

Recordemos que para la distribución de 10 actividades mediante 4 operadores de corte, es posible obtener de un mismo árbol de cortes 6,742 e<sup>14</sup> configuraciones diferentes, mientras que mediante estructuras de bahías flexibles se pueden obtener 4,644 e<sup>8</sup>.

A pesar de esto, estas estructuras proporcionan beneficios claros en la búsqueda de soluciones viables al problema. La limitación del campo de búsqueda se hace sobre una zona en la que las soluciones existentes son prometedoras desde el punto de vista geométrico, dado que las actividades pueden adoptar geometrías rectangulares con ratios alto/anchura aceptables. Por otra parte la configuración resultante, en la que las actividades son alineadas en las bahías, permite la introducción de pasillos rectos entre las mismas que facilitan el flujo de materiales.

#### 2.7.1.4.3 Space Partitioning Method

Este sistema de generación de layouts fue presentado por Kim y Kim en 1998 [Kim et al., 98] y, en combinación con un algoritmo de recocido simulado ofreció muy buenos resultados en la resolución de algunos problemas tipo de la bibliografía. De hecho, la solución que ofrece al problema de Armour y Buffa [Armour et al., 63] de 20 actividades es tomado como referencia en este trabajo. El algoritmo presentado por estos autores permite un elevado

control geométrico de las actividades, demostrado con la obtención de soluciones al problema antes mencionado, en las que las restricciones geométricas son muy estrictas. Como se podrá comprobar en la fase experimental de este trabajo, el método que se presenta supera las soluciones de Kim y Kim al problema de Armour y Buffa

El Space Partitioning Method representa las soluciones mediante una matriz de dos dimensiones (*Location Matrix*) que contiene información relativa a la posición de las actividades en la planta. El número de elementos de la matriz es igual o superior al de actividades a distribuir. Si es mayor, las actividades excedentes son consideradas ficticias y de área nula.

El método asigna las posiciones y espacios de las actividades en la planta descomponiendo la matriz de forma recursiva, y dividiendo el espacio en bloques rectangulares de acuerdo con los resultados de la descomposición de la matriz. Si la matriz se descompone verticalmente se aplica al dominio un corte vertical, y viceversa para un corte horizontal. Para descomponer la matriz se presentan tres alternativas:

**Método A:** Descomponer la matriz en vectores fila o columna y después descomponer cada vector en actividades individuales.

**Método B:** Descomponer la matriz en dos submatrices una de las cuales es un vector columna o fila, y aplicar luego al método A sobre las submatrices resultantes.

**Método C:** Si la matriz tiene  $f$  filas y  $c$  columnas, existen  $(f + c - 2)$  formas de descomponer la matriz en dos submatrices. Este método selecciona aquella que produce una menor cantidad de actividades que violan las restricciones geométricas. El método B se aplica después recursivamente a las submatrices obtenidas.

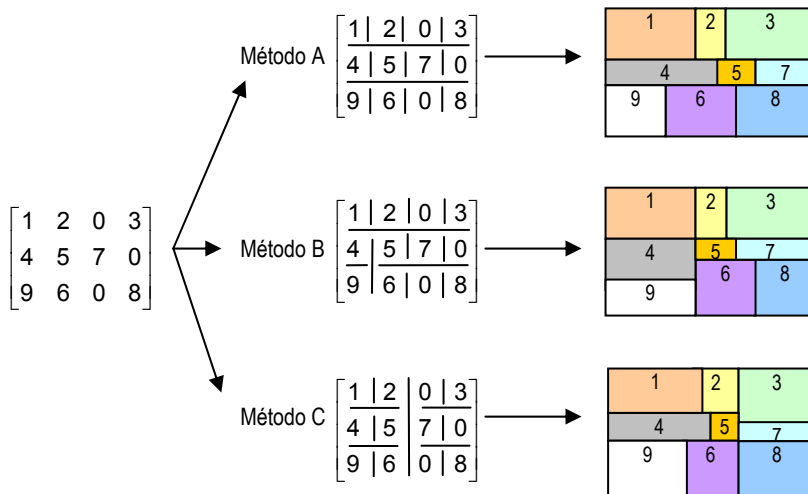


Figura 2.40: Descomposición de la matriz de localización en el Space Partitioning Method de Kim y Kim [Kim et al., 98].

### 2.7.1.5 Modelos analíticos

Se denominará así a los modelos que sitúan las actividades en el dominio referenciándolas a un sistema de coordenadas previamente definido [Heragu et al., 91; Tam et al., 91; Heragu, 92]. Las actividades adoptan generalmente formas rectangulares o cuadradas delimitadas por su ancho ( $a_i$ ) y su alto ( $b_i$ ). La situación de una actividad  $i$  queda




Figura 2.41: Formulación analítica del problema y distancia rectilínea entre actividades. Adaptado de [Santamarina, 95].

definida mediante las coordenadas de su centro de gravedad ( $x_i, y_i$ ) respecto a los ejes del sistema de referencia (Figura 2.41). La distancia entre actividades se mide normalmente (aunque hay otras formas), entre dichos centros de gravedad. En el caso de emplear como medida de la distancia entre las actividades la métrica Manhattan<sup>10</sup>, ésta vendría dada por la expresión:

$$d_{ij} = |x_i - x_j| + |y_i - y_j|$$

La aplicación de un algoritmo de optimización trata de obtener la situación de las actividades óptima desde el punto de vista de los criterios empleados. Estos criterios, plasmados en una función de coste, pueden ser cuantitativos, cualitativos o de ambos tipos. En cualquier caso, siempre deben cumplirse una serie de condiciones para que la solución obtenida sea considerada válida:

**Condición de no superposición:** Es lógico que la distribución de las actividades debe ser tal que no se produzcan solapamientos entre las áreas asignadas a cada una de ellas. Para ello se aplican unas restricciones geométricas que, con la notación empleada

<sup>10</sup> Las formas de medir las distancias entre las actividades una vez situadas en la distribución fue tratada en apartados anteriores.

anteriormente, pueden expresarse, para  $m$  actividades, como:

$$|x_i - x_j| \geq \frac{1}{2}(a_i + a_j) + d_{\min\_ij} \quad i=1, \dots, m-1; j=i+1, \dots, m$$

$$|y_i - y_j| \geq \frac{1}{2}(b_i + b_j) + d_{\min\_ij} \quad i=1, \dots, m-1; j=i+1, \dots, m$$

En estas expresiones  $d_{\min\_ij}$  es la distancia mínima que se desea que exista entre las actividades. Así pues, se garantiza que las actividades no se solapen y que exista siempre una distancia mínima entre ellas si esto es necesario.

**Condición de pertenencia al dominio:** En algunos casos de aplicación de estos modelos no se define un dominio de ubicación como tal, sino que éste será aquél capaz de albergar la distribución resultante. En otros casos existe un dominio de ubicación conocido, con un área determinada y una geometría conocida. Siendo éste un rectángulo con dimensiones vertical y horizontal  $H$  y  $V$  respectivamente, con el vértice inferior izquierdo coincidente con el origen del sistema de referencia escogido, las restricciones que aseguran que las actividades pertenecen al dominio serán:

$$x_i + \frac{a_i}{2} \leq H \quad i=1, \dots, m$$

$$y_i + \frac{b_i}{2} \leq V \quad i=1, \dots, m$$

Por último, puede exigirse a la distribución obtenida que las actividades posean formas determinadas, si es que las actividades se definen como de geometría flexible. Para ello se introducirían restricciones geométricas (por ejemplo ratios de aspecto dentro de un cierto intervalo) o restricciones de orientación de las actividades.

## 2.7.2 Clasificación de los métodos de resolución por la técnica empleada para solucionar el problema

Aunque en la bibliografía es posible encontrar clasificaciones diversas bajo el prisma de este mismo criterio [Santamarina, 95; Meller et al., 96c; González-Cruz, 01; Andrés, 01; Loiola et al., 04; González-García, 05; Ontiveros, 05], en este trabajo se propone la clasificación de los diferentes métodos en función de la técnica empleada para la resolución que se muestra en la Figura 2.42.

Como ya se indicó en el apartado 2.6, el problema de la distribución en planta en sus diversas formulaciones, y cuando el número de actividades supera cierto valor, se convierte en un problema al que es muy difícil encontrar solución (imposible en una praxis operativa y realista). Concretamente, empleando la formulación como problema cuadrático de asignación, y con medios convencionales de cálculo, sólo es posible encontrar soluciones óptimas a problemas con menos de 18 actividades [Kettani et al., 93]. Esto es así si se entiende como solución aquella distribución óptima a la que ninguna otra solución posible puede superar en la forma de evaluación escogida.

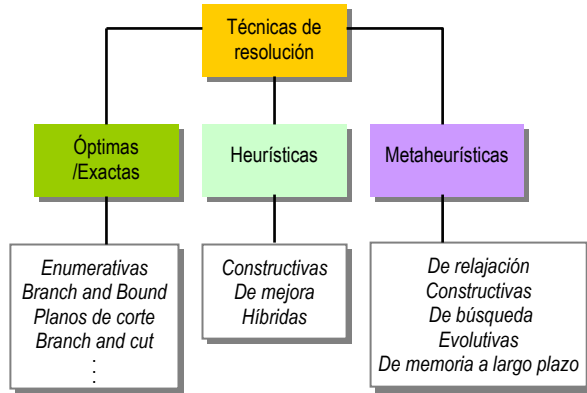


Figura 2.42: Clasificación de los métodos en función de la técnica empleada para la resolución.

Esto condujo necesariamente a la flexibilización del concepto de solución óptima, considerando como tal a la mejor solución que es posible encontrar en un determinado tiempo, y que resulta operativa y aplicable en la práctica. Bajo este nuevo enfoque, las técnicas heurísticas y metaheurísticas ofrecen resultados francamente aceptables y son la mayor parte de los procedimientos que aparecen en la bibliografía a partir de cierto momento [Loiola et al., 04]. Así pues, en principio las técnicas enumerativas o semi-enumerativas eran las predominantes en el intento de obtener soluciones óptimas. Posteriormente, y ante la complejidad del problema aparecerán y prevalecerán hasta la actualidad los métodos heurísticos y más recientemente metaheurísticos.

### 2.7.2.1 Métodos óptimos/exactos

Tratan de obtener la mejor solución global al problema. Son aplicados fundamentalmente a formulaciones del problema como cuadrático de asignación [Koopmans et al., 57] o bien mediante teoría de grafos (ver apartado 2.7.1.1.1). En general las actividades tienen igual área (monoárea) y las posiciones de asignación están fijadas a priori. Algunos de estos métodos son estrictamente **enumerativos**, es decir, tratan de evaluar todas las posibles soluciones al problema, lo cuál, dado el carácter complejo del mismo, los hace absolutamente ineficientes y poco operativos para problemas de cierta envergadura.

Además de estos métodos enumerativos, los destacables en este grupo son los algoritmos de **branch and bound**, los algoritmos de **planos de corte** y combinaciones de estos dos (por ejemplo *branch and cut*). La combinación de métodos *branch and bound* con la programación paralela está produciendo resultados prometedores en los últimos años. Se están resolviendo de forma exacta mediante estos algoritmos problemas tipo de gran envergadura. No obstante, estos éxitos están ligados al empleo de máquinas de gran potencia de cálculo.

### 2.7.2.1.1 Algoritmos branch and bound (ramificación y acotación)

Las primeras referencias a este tipo de algoritmos aplicables a problemas cuadráticos de asignación se pueden encontrar en [Gilmore, 62; Land, 63; Lawler, 63]. En [Loliola et al., 04] se realiza una enumeración exhaustiva de publicaciones que emplean algoritmos de *branch and bound*. Este tipo de algoritmos parten de una solución inicial generalmente obtenida mediante algún algoritmo heurístico. Esta solución inicial, sub-óptima pero factible, es tomada como una cota superior de los posibles valores de la función objetivo. A continuación el problema es separado en un número determinado de sub-problemas (ramificación), estableciéndose una cota inferior para cada uno de ellos que es comparada con la cota superior. Para un problema de minimización (por ejemplo), si una de las nuevas soluciones es factible y su evaluación proporciona un valor inferior a la cota superior, el nodo queda sondeado, es decir, marcado indicando que no es posible encontrar mejores soluciones por ese camino (acotación). Si la solución no es factible se divide de nuevo en subproblemas, repitiéndose de nuevo todo el problema. El proceso finaliza cuando todas las ramas están sondeadas. Estos métodos difieren unos de otros en la elección del límite o cota, en la estrategia de búsqueda, y las reglas y condiciones de eliminación de ramas.

Las técnicas *branch and bound* han evolucionado mucho en los últimos 40 años [Commander, 05]; Gilmore resolvió en 1962 un problema cuadrático de asignación de tamaño 8 [Gilmore, 62]; en el año 2000 Anstreicher y sus colaboradores [Anstreicher et al., 02] fueron capaces de resolver el problema tipo de tamaño 30 de Nugent (nug30).

### 2.7.2.1.2 Algoritmos de planos de cortes

El primer autor en aplicar algoritmos de planos de cortes (cutting plane algorithms) fue Gomory [Gomory, 58; Gomory, 63], haciéndolo sobre problemas modelizados como de programación entera mixta. Éste probó que, tras el número suficiente de iteraciones, el algoritmo localiza la solución óptima al problema. Sin embargo la baja eficiencia y la lentitud de convergencia de estos métodos hicieron que cayeran en desuso. El desarrollo de la teoría poliédrica permitió aumentar la eficiencia de estos algoritmos al facilitar la localización de *planos de corte* más adecuados a cada problema. La aplicación de los algoritmos de planos de corte en el ámbito de la distribución en planta comienza al final de la década de los 70 del pasado siglo [Kaufman et al., 78; Bazaraa et al., 79].

En un problema de optimización lineal con muchas restricciones, el procedimiento consiste en calcular la solución óptima para un pequeño subconjunto de ellas (relajación de restricciones). Encontrado dicho óptimo, si es posible localizar restricciones que son cumplidas por el problema original, pero incumplidas por la solución del problema “relajado”, se dice que esas restricciones son *planos de corte* del campo de soluciones del problema. Estas restricciones pueden ser añadidas al problema “relajado”, de manera que se “recorta” el campo de soluciones aproximándolo al del problema original. El procedimiento se repite hasta que el óptimo del problema relajado cumple las restricciones del problema original. Dado que ese óptimo lo es de un espacio de soluciones que incluye al del problema original, será también óptimo del problema original.

### 2.7.2.2 Métodos heurísticos

Como ya se ha indicado (ver 2.6), el problema de distribución en planta es intrínsecamente difícil de resolver de manera óptima. Para la mayoría de los problemas de distribución es imposible encontrar procedimientos exactos de solución que operen en tiempos realistas y con tecnologías asequibles al planificador medio. Como alternativa surgen los procedimientos heurísticos, que proporcionan soluciones factibles aceptablemente buenas, aunque no necesariamente óptimas, en tiempos de cálculo razonables.

Existen diversos intentos de dar una definición de los procedimientos heurísticos; por ejemplo en [Zanakis et al., 81] se puede leer que son:

*“...procedimientos simples, a menudo basados en el sentido común, que tienden a ofrecer una buena solución (aunque no necesariamente la óptima) a problemas difíciles, de un modo fácil y rápido”*

en [Adenso-Díaz et al., 96] se ofrecen ocho definiciones diferentes de heurística entre las que citamos:

*“Un método heurístico es un procedimiento para resolver un problema de optimización bien definido mediante una aproximación intuitiva, en la que la estructura del problema se utiliza de forma inteligente para obtener una buena solución”*

Acudiendo al diccionario de la Real Academia de la Lengua Española (edición electrónica en [www.rae.es](http://www.rae.es)) se encuentran las siguientes acepciones<sup>11</sup>:

*(Del griego εὕρησκειν, hallar, inventar).*

1. *adj. Perteneciente o relativo a la heurística.*
2. *f. Técnica de la indagación y del descubrimiento.*
3. *f. Busca o investigación de documentos o fuentes históricas.*
4. *f. En algunas ciencias, manera de buscar la solución de un problema mediante métodos no rigurosos, como por tanteo, reglas empíricas, etc.*

Como puede comprobarse, es difícil ofrecer una definición exacta de heurística, aunque en general, y sobre todo en la cuarta acepción de la definición de la Real Academia, se denota un cierto sentido de falta de metodología o sistematicidad en los métodos heurísticos. Nada más lejano a la realidad; los métodos heurísticos, y en particular los aplicados a la resolución del problema de distribución en planta, han logrado un elevado grado de desarrollo metodológico y, en muchos casos, los fundamentos de su funcionamiento han sido estudiados y enunciados.

El empleo de los procedimientos heurísticos es conveniente cuando se dan una o varias de las siguientes circunstancias [Adenso-Díaz et al., 96]

- Cuando no existe un método exacto de resolución;
- Cuando no se necesita la solución óptima;

---

<sup>11</sup> *Metaheurística*, un término que emplearemos posteriormente en este trabajo, no viene recogido en el diccionario de la Real Academia de la Lengua Española.



- Cuando los datos son poco fiables;
- Cuando existen limitaciones de tiempo o espacio de almacenamiento a la hora de obtener una respuesta al problema;
- Como un paso intermedio en la aplicación de otro algoritmo.

Desde la década de los 60 en la que aparecen los primeros heurísticos aplicados al problema de la distribución en planta, la evolución de las diferentes técnicas ha llevado a la existencia de innumerables métodos de resolución. Cada uno de ellos es aplicable en circunstancias particulares (más o menos generales), o hace énfasis en determinados aspectos del problema. También son varias las posibles clasificaciones que es posible hacer de las heurísticas. En el presente trabajo se emplea como criterio de clasificación la forma de generar las soluciones, agrupándose los métodos en: métodos constructivos, métodos de mejora y métodos híbridos.

#### 2.7.2.2.1 Métodos constructivos

De manera general los métodos constructivos generan los layouts escogiendo una tras otra las actividades a distribuir, y colocándolas en determinadas posiciones del dominio de ubicación. Un algoritmo, generalmente heurístico, determina el orden en que se seleccionan las actividades y la posición en que se situarán en el dominio según se valoren las relaciones de proximidad. Operando de esta manera se van añadiendo las actividades al dominio de ubicación y se van construyendo las soluciones sin que sea necesario partir de una distribución inicial. Las diferencias fundamentales entre los algoritmos de este tipo estriban en la forma de seleccionar las actividades y en la manera de elegir las posiciones que ocuparán. Algunos métodos constructivos utilizan una función denominada “miope” que añade cada componente a la solución de tal manera que se obtenga el máximo beneficio en cada paso.

A este tipo de algoritmos pertenecen, por ejemplo: HC66 [Hillier et al., 66], ALDEP [Seehof et al., 67], CORELAP [Lee et al., 67], RMA [Muther et al., 70], MAT [Edwards et al., 70], PLANET [Apple et al., 72], LSP [Zoller et al., 72], FATE [Block, 78], SHAPE [Hassan et al., 86], NLT [Van Camp et al., 91] y QLAARP [Banerjee et al., 92]. De manera general, la mayor parte de los métodos basados en técnicas de corte o teoría de grafos y algunos que hacen uso de la lógica difusa pertenecen a este grupo. Se expone a continuación de manera breve el funcionamiento de los más significativos.

#### **Aldep**

El método ALDEP (acrónimo de *Automated Layout Design Program*) fue presentado por Seehof y Evans en [Seehof et al., 67]. Esencialmente actúa colocando las actividades secuencialmente en el dominio siguiendo una curva de llenado de espacios (2.7.1.3.1) que puede seguir trayectorias diversas: comenzando por cualquier esquina de la planta, zigzagueando vertical u horizontalmente, etc.

Habitualmente el primer elemento de la secuencia se escoge aleatoriamente, los restantes se escogen usando como criterio las relaciones entre actividades expresadas en la Tabla Relacional de Actividades (obtenida a partir del S.L.P.). La siguiente actividad a introducir en la secuencia será aquella cuya necesidad de cercanía a la anterior supere cierto

mínimo establecido como parámetro del algoritmo. De no existir ninguna que cumpla ese requisito se selecciona una actividad de manera aleatoria. Este proceso continúa hasta haber introducido todas las actividades en la distribución.

En una primera iteración se generan tantos layouts como se decida (siendo esta cantidad un parámetro del algoritmo), evaluando cada uno mediante la suma de los valores numéricos de los ratios de proximidad de todos los departamentos adyacentes a uno dado. A esta cantidad se le denomina *total closeness rating* (TCR). Así pues la evaluación se basa en criterios cualitativos, dando valores numéricos a los diferentes ratios de proximidad.

A=64; E=16; I=4; O=1; U=0; X=-1024;

La mejor puntuación obtenida se emplea en la siguiente generación como la mínima aceptable. El proceso continúa hasta que en una generación todos los layouts obtenidos poseen valoraciones inferiores a la mínima aceptable.

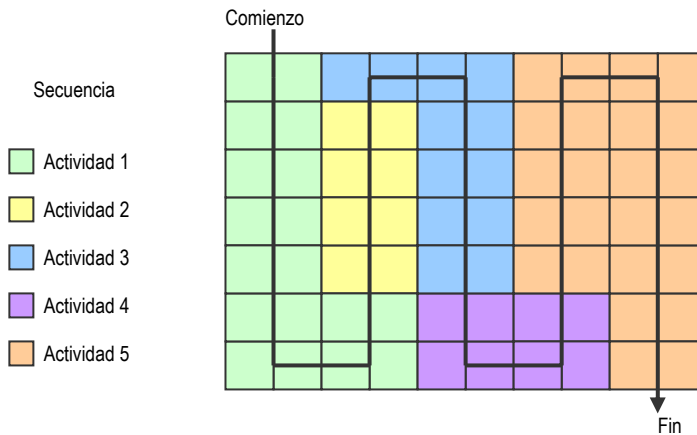


Figura 2.43: Posible estrategia de relleno en ALDEP.

**Corelap**

CORELAP (*Computerized Relationship Layout Planning*) es un procedimiento constructivo que introduce secuencialmente las actividades en la distribución. La primera actividad seleccionada es aquella con un mayor TCR y es colocada en el centro geométrico de la distribución. El criterio para establecer la ubicación adecuada de cada una de las siguientes actividades se basa en el *Índice de colocación* (IC). La ubicación con un mayor IC será la seleccionada. Para una actividad *i* en una distribución en la que *n* actividades están ya colocadas el IC se define como:

$$IC_i = \sum_{j=1}^n V(r_{ij}) \cdot L_{ij}$$




Figura 2.44: Colocación de actividades en CORELAP.

siendo  $V(r_{ij})$  el peso asociado a la intensidad relacional entre la actividad a ubicar  $i$ , y la  $j$ -ésima de las  $n$  ya colocadas, y  $L_{ij}$  es la longitud de contorno común a las actividades  $i$  y  $j$ -ésima. Cuando existen varias alternativas con igual puntuación se escoge la más compacta, es decir, la inscrita en un rectángulo con menor área.

### **Planet**

PLANET (*Plant Layout Analysis and Evaluation Technique*) realiza la asignación de los recursos espaciales en tres etapas. En la primera etapa se establece el coste del flujo de materiales entre las actividades. Cada actividad lleva asociada un índice de prelación, desde 1 hasta 9 en orden descendente de prioridad para entrar en el layout. En la segunda fase, a partir de estos valores, el flujo entre actividades y el índice de prioridad, se establece un criterio para establecer la secuencia con la que las actividades entrarán en el layout. La tercera fase asigna las ubicaciones a las actividades en el orden establecido en la fase 2.

#### 2.7.2.2.2 Métodos de mejora

Los métodos de mejora parten de una solución al problema de distribución a partir de la cuál, realizando modificaciones sistemáticas, obtienen diferentes soluciones. Generalmente las soluciones iniciales son generadas de manera aleatoria, pero en ocasiones son el fruto de la aplicación de alguna heurística o de alguno de los métodos de construcción. Tras realizar la modificación de una solución ésta es evaluada; si la nueva solución es mejor que la anterior ésta permanece como mejor solución localizada. Este proceso continúa hasta que no es posible localizar mejores soluciones. Las modificaciones que generan una solución a partir de la anterior suelen ser mecanismos de intercambio de la posición de las actividades.

A este tipo de algoritmos pertenecen, entre otros métodos: CRAFT [ Armour et al., 63], H63 [ Hillier, 63], HC63-66 [ Hillier et al., 66], COL [ Vollmann et al., 68], Biased Sampling [ Nugent et al., 68], FRAT [ Khalil, 73], TSP [ Hitchings et al., 76], COFAD [ Tompkins et al., 76], LOGIC [ Tam, 92a], MULTIPLE [ Bozer et al., 94], FLEX-BAY [ Tate et al., 95] y SABLE [ Meller et al., 96a]. Además, pertenecen a este grupo la mayor parte de las técnicas basadas en búsqueda tabú, recocido simulado y algoritmos genéticos. Las características de estas metaheurísticas permiten a los métodos de mejora escapar de óptimos locales mediante la aceptación de movimientos que no generen necesariamente una mejor solución que la actual. De este tipo de métodos, CRAFT es quizá el más conocido; muchos otros métodos son variaciones realizadas sobre la base de CRAFT.

### **Craft**

CRAFT (Computerized Relative Allocation Facilities Techniques) parte de una solución inicial al problema que puede generarse por cualquier método. A partir de esa solución, y mediante intercambio de actividades, se trata de localizar una configuración de la distribución que, respetando las restricciones del problema, sea óptima bajo los criterios empleados para la evaluación.

Los intercambios de actividades son posibles si las actividades interesadas poseen igual área o una frontera común. Evaluando los posibles intercambios es posible escoger aquel que permite un mayor descenso del coste respecto a la configuración espacial actual. El proceso se repite siguiendo una estrategia *steepest descent* que persigue un máximo descenso del coste.




Figura 2.45: Intercambio de dos actividades en CRAFT.

### 2.7.2.3 Métodos híbridos

El término algoritmo híbrido se aplica generalmente a aquéllos que poseen las características de los métodos exactos y de los sub-óptimos [Bazaraa et al., 83], o también a la combinación de diferentes heurísticas en un solo algoritmo [Fleurent et al., 94; Kado et al., 95; Glover et al., 95; Koakutsu et al., 95; Mavridou et al., 97; Preux et al., 99; Lee et al., 02; Balakrishnan et al., 03b; Misevicius, 03c; Rodriguez et al., 04]. Sin embargo, en el contexto de este apartado, se entiende por algoritmo híbrido aquél que incluye tanto técnicas constructivas como de mejora [Scriabin et al., 85; Kusiack et al., 87].

### 2.7.2.3 Metaheurísticas

Las técnicas metaheurísticas aplicadas al problema de distribución en planta serán abordadas en profundidad en el capítulo siguiente. Este tipo de métodos es en la actualidad el más empleado debido a los buenos resultados que proporcionan.

En el análisis bibliográfico realizado en [Loiola et al., 04] sobre las publicaciones dedicadas al problema cuadrático de asignación esto queda patente, pues se observa que el número de aportaciones que emplean técnicas metaheurísticas duplica a los que emplean métodos heurísticos o exactos (Figura 2.46).




Figura 2.46: Métodos de resolución empleados en la bibliografía.

Adaptado de [Loiola et al., 04].

# 3

**Metaheurísticas y redes neuronales para la distribución en planta de actividades industriales**

### 3. METAHEURÍSTICAS Y REDES NEURONALES PARA LA DISTRIBUCIÓN EN PLANTA DE ACTIVIDADES INDUSTRIALES

#### 3.1. Introducción

La teoría de la complejidad nos indica que, para los problemas de distribución en planta de cierta envergadura y con un número suficiente de restricciones, es muy improbable encontrar métodos exactos de resolución. El empleo de técnicas heurísticas permite localizar soluciones aceptables (sub-óptimos) en tiempos razonables de cálculo. No obstante, son las metaheurísticas las que ocupan la mayor parte de la bibliografía dedicada al problema y las que mejores soluciones han proporcionado.

Osman [Osman, 95] proporciona una definición acertada de metaheurística:

*“Dentro de la clase denominada metaheurísticas se incluyen todos aquellos procedimientos que en un proceso iterativo, guían a una heurística subordinada combinando inteligentemente diferentes conceptos tomados de analogías de la naturaleza, y exploran el espacio de soluciones utilizando estrategias de aprendizaje para estructurar la información, con el objeto de encontrar eficientemente soluciones cercanas al óptimo.”*

Así pues, las metaheurísticas son estrategias *inteligentes* para mejorar procedimientos heurísticos muy generales, y que ofrecen muy altos rendimientos. En general emplean analogías con sistemas naturales o sociales [Colorni et al., 96]. Pueden clasificarse en los siguientes grupos según [González-García, 05]:

- **De relajación:** utilizan modelos relajados del original para la solución del problema. Se entiende por relajación la modificación, flexibilización o eliminación de restricciones del problema original.
- **Constructivas:** tratan de obtener soluciones al problema a partir del análisis y selección paulatina de las componentes que las forman. Se parte de una estructura de solución vacía a la que se incorporan iterativamente sus diferentes elementos. De este estilo es por ejemplo GRASP (Greedy randomized adaptative search procedures), que modifica una estrategia *greedy* incluyendo pasos aleatorios para seleccionar los elementos a incluir en una solución.
- **De búsqueda:** procedimientos que emplean transformaciones denominadas *movimientos* para recorrer el espacio de búsqueda cercano a una solución (vecindario de la solución actual). Pueden distinguirse varios subtipos:
  - De búsqueda local: establecen pautas de selección iterativa de las soluciones vecinas a la actual que dan lugar a búsquedas heurísticas de alto rendimiento.
  - De búsqueda global: emplean diversos métodos para escapar de óptimos locales. Tres de ellos son:
    - Re-arrancar la búsqueda desde otra posición del espacio de soluciones (metaheurísticas de arranque múltiple o *Multistart*)

- Modificar la estructura del entorno de una solución (búsqueda por entornos variables o *variable neighborhood search*).
  - Permitir soluciones que no mejoran el valor de la función objetivo de la solución actual con cierta probabilidad. Este procedimiento permite escapar de óptimos locales a metaheurísticas como el recocido simulado.
- De búsqueda basada en poblaciones: en lugar de recorrer el espacio de soluciones partiendo de un único punto, es una población de soluciones iniciales la que recorre el espacio de manera simultánea e interactuando entre ellas. Contemplan mecanismos (operadores) para generar nuevas soluciones a partir de las ya existentes. A este grupo pertenecen por ejemplo los algoritmos meméticos, la búsqueda dispersa (*scatter search*) o los algoritmos de hormigas.
- **Evolutivas:** en éstas, un conjunto de soluciones evoluciona en el espacio de búsqueda estableciendo procedimientos de guiado del proceso. Se distinguen por la forma en que combinan la información de las diferentes soluciones para obtener otras nuevas. A este grupo pertenecen por ejemplo los algoritmos genéticos
  - **De memoria a largo plazo:** metaheurísticas de aprendizaje que emplean la memoria del proceso de búsqueda para mejorar su rendimiento. El paradigma de este tipo de algoritmos es la búsqueda tabú.

Otro procedimiento empleado (en menor medida) en la resolución del problema de distribución en planta, basado en una analogía con la naturaleza, son las redes neuronales. Éstas consisten en estructuras de procesamiento distribuido, paralelo y adaptativo que son capaces de aprender a partir de ejemplos y que se inspiran en la estructura cerebral humana [Martín et al., 97].

El presente capítulo pretende exponer los procedimientos metaheurísticos más empleados en la resolución del problema de distribución en planta y su modo de funcionamiento.

## 3.2. Recocido Simulado (Simulated Annealing)

### 3.2.1 Definición general

El recocido simulado como técnica de búsqueda aleatoria dirigida fue introducido por Kirkpatrick, Gelatt y Vecchi en 1983 [Kirkpatrick et al., 83], basándose en una analogía con el proceso de enfriamiento lento de los metales, modelizado previamente en [Metropolis et al., 53]. Kirkpatrick y sus colaboradores emplearon este método en la resolución de problemas de optimización combinatoria que aparecen en el diseño de circuitos impresos.

El recocido (*annealing*) de los metales es un proceso que permite que estos materiales

adquieran de nuevo la ductilidad o temple que pierden al trabajarlos<sup>12</sup>. Lo que se persigue mediante este proceso es que los átomos del material adopten una estructura estable o de mínima energía. Para ello se calienta la sustancia hasta altas temperaturas permitiendo que sus partículas puedan moverse con libertad. Posteriormente se lleva a cabo un enfriamiento lento, de tal forma que dichas partículas adopten, para cada temperatura, la configuración más estable posible. En el proceso de enfriamiento el metal va recorriendo sucesivos estados de equilibrio hasta alcanzar la temperatura ambiente. Si se produjera un cambio brusco en la temperatura, las estructuras cristalinas resultantes serían defectuosas o se alcanzaría un estado metaestable con estructuras localmente óptimas.

### 3.2.1.1 El algoritmo Metropolis

Nicholas Metropolis y sus colaboradores [Metropolis et al., 53] propusieron en 1953 un método para calcular el estado energético de un sistema de partículas que aprovechaba las capacidades de cálculo de los ordenadores. La base de dicho método es la simulación Montecarlo simple.

#### 3.2.1.1.1 La simulación Montecarlo

Una simulación Montecarlo permite explorar un espacio de búsqueda de soluciones para obtener información del mismo. De manera simple, esta simulación realiza un número elevado de exploraciones del espacio, tabulando los resultados obtenidos de dichos sondeos. A partir de dichos resultados es posible obtener información sobre el espacio de soluciones. Como ejemplo, si se quiere determinar la probabilidad de lanzar una moneda al aire y que caiga mostrando “cruz”, con la premisa de que su posición de partida en la mano sea mostrando “cara”, la simulación Montecarlo exploraría el espacio de soluciones realizando el lanzamiento un número determinado de veces, partiendo de la posición “cara”, y registrando el resultado. El cociente entre el número de veces que se obtiene una “cruz” y el número de lanzamientos proporciona la probabilidad de obtener “cruz” partiendo de “cara”.

El método Montecarlo puede emplearse, entre otras posibilidades, para calcular prácticamente cualquier integral o para determinar la calidad de los generadores de números aleatorios uniformes. El número de exploraciones necesario para obtener resultados aceptables puede determinarse mediante los métodos Jackknife [Quenouille, 49] o Bootstrap [Efron, 79].

La simulación Montecarlo simple explora el espacio de soluciones realizando movimientos aleatorios, y cualquier punto del espacio es considerado válido para obtener información sobre la configuración de dicho espacio. Este procedimiento es aceptable en determinadas aplicaciones, sin embargo, resulta inadecuado para, por ejemplo, espacios que representan estados energéticos de sistemas de partículas.

Suponiendo un sistema de partículas formado por átomos de helio, la posición de cada átomo en el espacio vendría representada por tres coordenadas. Cada átomo de helio interactúa con cada uno de los restantes, siendo la energía total del sistema la suma de cada una de las interacciones entre pares de átomos. Si se emplea el método Montecarlo simple

---

<sup>12</sup> Según la definición de la Real Academia de la Lengua Española.



para calcular la energía media de dicho sistema, los átomos se distribuirían dando valores aleatorios a las coordenadas de cada partícula en cada simulación, registrando la energía de cada una de las configuraciones resultantes. La energía media se calcularía como el cociente entre la suma de la energía de cada configuración y el número total de configuraciones exploradas. La colocación aleatoria en el espacio de los átomos de helio puede provocar que, para alguna de las configuraciones generadas, dos átomos sean situados lo suficientemente cerca como para que su energía de interacción sea virtualmente infinita. De esta manera, la energía de una de las configuraciones es infinita y, por tanto, la energía media del sistema es infinita. En realidad dos átomos de helio nunca se situarían tan cerca en condiciones normales, por lo que el cálculo de la energía media resultaría fallido.

### 3.2.1.1.2 El método Metropolis

El método Metropolis es una modificación del Montecarlo. La diferencia fundamental estriba en la forma de generar las configuraciones del sistema que serán analizadas, para evitar situaciones como las descritas en el apartado anterior. Cada nueva configuración se genera modificando ligeramente la configuración anterior. Así, por ejemplo, la nueva disposición del conjunto de átomos de helio se creará variando leve y aleatoriamente las posiciones de los átomos de la configuración previa. Esta nueva configuración se somete a un criterio de aceptación. Es aceptada si la energía de la nueva configuración es inferior a la energía de la configuración previa. Si la energía de la nueva configuración es superior se emplea un criterio de aceptación Boltzmann:

$$e^{-\frac{\Delta E}{K_B T}}$$

donde:

$\Delta E$  es la variación de la energía del sistema respecto a la configuración anterior;

$K_B$  es la constante de Boltzmann y

T es la temperatura del sistema.

El uso de esta probabilidad de aceptación implica que la media de cualquier propiedad de una muestra, por ejemplo la energía, es igual a la media Boltzmann de esa propiedad, como determina la Ley de Distribución de Boltzmann, si la muestra es suficientemente grande. Este valor será dependiente de la temperatura del sistema.

### 3.2.1.2 La propuesta de Kirkpatrick, Gelatt y Vecchi

En [Kirkpatrick et al., 83] se propone emplear una simulación Metropolis Montecarlo para determinar la configuración de mínima energía, y por tanto más estable, de un sistema. El método consiste en elevar la temperatura del sistema para permitir una evolución rápida del mismo hacia una configuración estable. La temperatura se disminuye progresivamente permitiendo en que el sistema evolucione hacia sucesivas configuraciones de mínima energía. Este proceso de enfriamiento lento es conocido como "annealing" y el método propuesto como "Simulated Annealing" (Recocido Simulado).

El recocido simulado comienza realizando una simulación Metropolis del sistema a alta temperatura. Dado el criterio de aceptación de la simulación Metropolis, será aceptado un elevado porcentaje de configuraciones que supongan incrementos en la energía del sistema. Tras un número de simulaciones suficiente, la temperatura es disminuida y vuelve a realizarse una simulación Metropolis. Este proceso continua hasta que el sistema alcanza una temperatura final previamente definida. Conforme disminuye la temperatura disminuye la probabilidad de aceptar configuraciones que supongan un incremento de la energía del sistema. Así pues, a temperaturas altas son las características del sistema que más afectan a su estado energético las que guían el proceso, mientras que al disminuir la temperatura son los detalles de la configuración los que predominan en la evolución.




Figura 3.1: Escape de un óptimo local mediante la aceptación de configuraciones de mayor energía en el “Simulated annealing”.

Esta técnica posee una elevada capacidad para escapar de los mínimos locales gracias al empleo del criterio Metropolis de aceptación de configuraciones de mayor energía (Figura 3.1)<sup>13</sup>. Desde su aparición en 1983, el ámbito de aplicación del recocido simulado se ha extendido a todo tipo de problemas de optimización combinatoria, entre los cuales se encuentra el problema de la distribución en planta.

### 3.2.2 Estructura del algoritmo

El recocido simulado es una estrategia heurística de búsqueda por entornos no determinista. Definido el entorno  $\mathbf{N}$  de un elemento  $\mathbf{x}_0$ , el paso a otro elemento  $\mathbf{x}_1 \in \mathbf{N}(\mathbf{x}_0)$  es aceptado si el valor de la función objetivo para  $\mathbf{x}_1$  es inferior que para  $\mathbf{x}_0$ . En caso de resultar superior la aceptación se realiza con una probabilidad:

$$p = e^{-\frac{\Delta F}{T(M)}}$$

donde  $\Delta F$  es la diferencia de los valores de la función objetivo para  $\mathbf{x}_1$  y  $\mathbf{x}_0$  ( $F(\mathbf{x}_1) - F(\mathbf{x}_0)$ ) y  $T(M)$  es un parámetro que decrece durante la ejecución del algoritmo denominado temperatura y que varía para cada iteración  $M$ . La temperatura en una iteración  $M+1$  es

<sup>13</sup> En todo el presente documento las representaciones gráficas de los espacios de soluciones, como la de la Figura 3.1, adoptarán el convenio de que la aptitud de una solución es inversamente proporcional a la altura; las zonas más altas de la topografía serán “peores” soluciones que las más profundas.

función de la temperatura de la iteración precedente  $M$  según la expresión:

$$T_{M+1}=f(T_M)$$

Otras versiones del algoritmo aplican la denominada aceptación con umbral [Dudek et al., 90], en las que la función probabilística es reemplazada por un umbral determinista  $T_k$ , de manera que un  $x_1 \in N(x_0)$  es aceptado si  $\Delta F$  es menor que  $T_k$ . Los valores que toma  $T_k$  se generan mediante una función que tiende a cero durante la ejecución.

En [Downsland, 93b] se propone variar la función de Boltzmann empleando una constante  $K$  de forma que la probabilidad de aceptación sea:

$$p = e^{-\frac{\Delta F}{T(M)+K}}$$

resultando este procedimiento adecuado para problemas en los que la geometría del espacio de soluciones es muy irregular.

El algoritmo consiste en dos bucles anidados. El exterior controla la temperatura y el interior realiza una simulación Metropolis a la temperatura fijada por el bucle exterior. En la Figura 3.2 se esquematiza al algoritmo mediante un diagrama de flujo. La manera en que se realiza la disminución de la temperatura en el bucle externo se denomina *esquema de enfriamiento*, y será tratado en el apartado 3.2.2.5. La simulación Metropolis realizada en el bucle interno del algoritmo no necesita realizar un número de intentos tan elevado como una simulación Metropolis pura. Mientras que en éstas se intenta reproducir lo más fielmente posible una distribución de Boltzmann en cada temperatura, en un algoritmo de recocido simulado, sólo es necesaria una exploración razonable del espacio de búsqueda. El número de pasos necesario depende, por tanto, de las características del espacio de soluciones. Este aspecto será tratado también en 3.2.2.5.

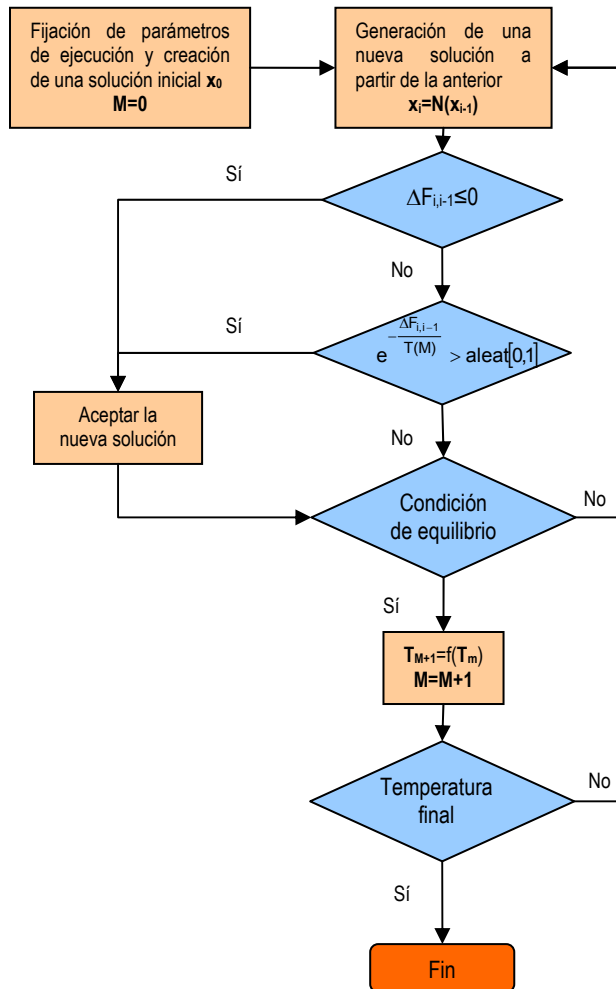


Figura 3.2: Simulated annealing aplicado a un problema de optimización (adaptado de [Santamarina, 95]).

### 3.2.2.1 Generación de la solución inicial

Para lograr que la evolución del algoritmo sea independiente de la solución inicial empleada (característica primordial de cualquier heurística), las primeras iteraciones se realizan a una temperatura muy elevada. De esta manera se consigue que en sus primeros pasos se recorran soluciones muy alejadas entre sí. La forma de generar la solución inicial es, habitualmente, aleatoria. Dado que la elevada temperatura de comienzo permitirá la aceptación de soluciones peores que la inicial, no es necesaria la búsqueda de una buena solución de partida mediante alguna heurística preliminar. En algunos casos se inicia el algoritmo desde varios puntos del espacio para lograr una exploración más exhaustiva, y en

otros se toma como punto de partida la mejor solución de una muestra aleatoria.

### 3.2.2.2 Determinación de la temperatura inicial

Como se ha indicado en 3.2.2.1, la temperatura inicial debe ser tal que permita una elevada probabilidad de aceptación de soluciones menos eficientes que la inicial. Es habitual escoger  $T_0$  de tal suerte que la probabilidad de aceptación sea:

$$p = e^{-\frac{\Delta F}{T_0}} \approx 1$$

En [Kirkpatrick et al., 83] se propone determinar empíricamente la temperatura inicial. En primer lugar se determina la probabilidad de aceptación deseada. Como paso previo a la ejecución del algoritmo se realizan una serie de iteraciones de prueba, en las que se determina la temperatura inicial que proporciona dicha probabilidad de aceptación.

Otras posibilidades son las propuestas de [Johnson et al., 91] y las de [Kouvelis et al., 92]. En la primera la temperatura inicial se determina de nuevo experimentalmente, fijando la probabilidad  $p_0$  de aceptar soluciones un  $\mu$  por uno peores que la inicial:

$$T_0 = \frac{\mu}{-\ln(p_0)} F(x_0)$$

En la segunda, se calcula el incremento del coste medio de una serie de transacciones y se fija de antemano el valor  $\chi_0$  (ratio de soluciones evaluadas-aceptadas), quedando la temperatura inicial determinada por la expresión:

$$T_0 = \frac{\overline{\Delta F}^{(+)}}{\ln(\chi_0^{-1})}$$

### 3.2.2.3 Definición del entorno de una solución

El simulated annealing es un proceso de búsqueda por entornos. Se define el entorno  $N$  de una solución  $x_0$ , como todas aquellas soluciones accesibles directamente desde  $x_0$ . Algunos autores han señalado la importancia de la definición del entorno y su influencia sobre los procedimientos de búsqueda local [Cerny, 85]. Evidentemente la definición del entorno dependerá de la forma de generar las soluciones y, por lo tanto, del tipo de problema a resolver. En el caso de la distribución en planta una posible forma de generar soluciones sucesivas es intercambiar la posición de dos actividades. En este caso, el entorno de una solución dada será el formado por todas las distribuciones que es posible generar mediante el intercambio de la posición de dos actividades de la distribución inicial.

Los algoritmos básicos emplean un método probabilista de exploración del entorno, lo cuál puede provocar la aparición de ciclos exploratorios visitando sucesivamente las mismas soluciones. Implementaciones más elaboradas del algoritmo emplean técnicas para evitar la aparición de ciclos, como el empleo de listas de soluciones ya visitadas similares a las de los

algoritmos Tabú (apartado 3.3.2). En otros casos se realiza una exploración ordenada del entorno de las soluciones, resultando este método más eficiente que el enfoque probabilista clásico [Connolly, 90].

### 3.2.2.4 El criterio de parada (criterio de congelación)

Existen diferentes criterios en base a los cuales el algoritmo detendrá su evolución. El más sencillo de estos es predefinir un número de iteraciones a completar antes de la detención. Otro es definir una temperatura de congelación, alcanzada la cuál, el algoritmo se detiene. Esta temperatura de congelación puede ser un valor prefijado ( $T_f=0$ , por ejemplo) o bien una expresión más elaborada como la propuesta en [Lundy et al., 86], en la que  $\varepsilon$  es un estimador de la diferencia de costes entre la solución final y el óptimo global.

$$T_f \approx \frac{\varepsilon}{\ln(n)}$$

En [Johnson et al., 89] se propone definir una constante  $k$ , que indica un número de etapas consecutivas tras la cuál se detendrá el proceso si no se produce una mejora de la última solución obtenida de un determinado porcentaje.

### 3.2.2.5 Condición de equilibrio y esquema de enfriamiento

El mecanismo del bucle interno de un algoritmo de recocido simulado es asimilable a una cadena de Markov, cuyo parámetro de control es la temperatura fijada en el bucle externo. Para una determinada temperatura se realiza una secuencia de experimentos, en la que el resultado de cada uno depende únicamente del resultado del experimento anterior. Se entiende aquí experimento como el proceso realizado con cada una de las configuraciones del sistema, y es sabido que cada configuración es obtenida seleccionando un elemento del entorno de la configuración anterior.

Sin embargo, la implementación real del algoritmo sólo puede realizar una convergencia asintótica aproximada. El número de experimentos realizados en cada temperatura debe ser necesariamente finito, y la disminución de la temperatura no puede ser continua sino que evoluciona de manera discreta. Así pues, la implementación habitual del algoritmo puede tratarse como una secuencia de cadenas de Markov homogéneas de longitud finita, en las que el parámetro de control es la temperatura.

Determinando la longitud de las cadenas de Markov se determinará el número de pasos a realizar por el algoritmo en cada temperatura. Se considera que el algoritmo cumple la condición de equilibrio para una temperatura dada cuando la cadena de Markov alcance la longitud establecida para esa temperatura.

Existen diferentes propuestas para la definición de las condiciones de equilibrio. La más simple es que la longitud de la  $k$ -ésima cadena de Markov  $L_k$  dependa polinómicamente del tamaño del problema. De otra forma, puede definirse un número mínimo de configuraciones analizadas para cada temperatura, teniendo la precaución de acotar superiormente la longitud de las cadenas de Markov. Cuando la temperatura desciende disminuye la probabilidad de aceptar configuraciones que no mejoren la actual, por lo que la longitud de

las cadenas puede tender a infinito cuando la temperatura se acerca a cero. Para evitar esto se define una constante que determina la longitud máxima de las cadenas. En [Kirkpatrick et al., 83] se propuso que el valor de esta constante fuera igual al número de incógnitas el problema a resolver. Por último, otras propuestas condicionan la longitud de una cadena de Markov a la longitud de las cadenas anteriores.

Una vez alcanzada la condición de equilibrio a una temperatura dada se debe hacer evolucionar la temperatura. La forma de evolución es denominada *esquema de enfriamiento*, *programa de enfriamiento*, o *ley de evolución de la temperatura*.

El grado de enfriamiento  $\alpha$  regula la evolución de la temperatura en cada iteración. En la definición de  $\alpha$  debe llegarse a un compromiso entre una disminución rápida que puede producir una convergencia prematura del algoritmo, y una evolución lenta en exceso que prolonga demasiado el tiempo de cálculo.

El esquema de enfriamiento más sencillo es una expresión de tipo geométrico [Downsland, 93a] como:

$$T_M = \alpha T_{M-1}$$

en la que  $\alpha$  es un real perteneciente a  $]0,1[$ .

El valor de dicho intervalo varía según autores y tipo de problema. En [Kuik et al., 90] se plantea, para problemas de determinación de tamaño de lotes, que  $\alpha$  tome valores en  $[0.8, 0.99]$ , aunque lo habitual es que oscile entre 0,5 y 0,99.

Alternativamente es posible dar al enfriamiento carácter potencial, de manera que sea más rápido a temperaturas elevadas y más lento a temperaturas bajas, mediante expresiones del tipo:

$$T_M = \alpha^M T_0$$

Otros autores plantean esquemas de enfriamiento más complejos como es el caso de [Lundy et al., 86], que plantean determinar la temperatura en una iteración M como:

$$T_M = \frac{T_{M-1}}{1 + \beta T_{M-1}} \quad \text{con} \quad \beta \ll \frac{1}{\max_j (F(x_j) - F(x))} \quad \forall j$$

partiendo de una temperatura inicial definida como:

$$T_0 \gg \max_j (F(x_j) - F(x)) \quad \forall x_i, x$$

o el caso de [Maniezzo et al., 95] que en la resolución del problema de asignación cuadrática mediante recocido simulado emplea el esquema:

$$T_M = \frac{T_0}{1 + \beta T_{M-1}}$$

u [Osman, 93] que propone adaptar la temperatura a la forma de evolución del algoritmo. En su aplicación al problema del *vehicle routing*, la temperatura es aumenta cuando siguiendo el esquema de enfriamiento no se consigue mejorar las soluciones. Se trata pues de un

procedimiento de diversificación de la búsqueda similar al empleado en los algoritmos de búsqueda tabú (véase el apartado 3.3.4.2). Un sistema parecido es empleado en [Downsland, 93b], que reduce la temperatura si un movimiento se acepta y la incrementa si se rechaza mediante la fórmula:

$$T_M = \frac{T_{M-1}}{1 + \delta T_{M-1}}$$

donde  $\delta$  es parámetro que se adapta en función de la aceptación o no de las soluciones.

Finalmente [Connolly, 90] propone un algoritmo en dos fases para su aplicación en la resolución del problema cuadrático de asignación. Durante la primera fase se registra la temperatura a la que ha sido encontrada la mejor solución, realizando en la segunda fase una exploración exhaustiva a esa temperatura.

Existe otra tendencia en la definición de la ley de evolución de la temperatura en la que se define una variación constante. Generalmente este tipo de algoritmos definen una longitud variable para las cadenas de Markov.

### **3.2.3 Aplicación del recocido simulado a la distribución en planta**

Estudios y aplicaciones de algoritmos de recocido simulado en la resolución del problema de la distribución en planta pueden encontrarse en [Heragu et al., 92; Kouvelis et al., 92; Tam, 92a; Suresh et al., 93; Contero-González, 95; Koakutsu et al., 95; Chiang et al., 96; Meller et al., 96a; Mavridou et al., 97; Kim et al., 98; Baykasoglu et al., 01; Kuppusamy, 01; Chen et al., 02; Balakrishnan et al., 03a; Misevicius, 03b; González-García, 05].

## **3.3. Búsqueda Tabú (Tabu Search)**

### **3.3.1 Definición general**

La técnica de la búsqueda tabú fue introducida de manera general por Fred Glover en 1986 [Glover, 86], aunque se basa en ideas que el mismo autor presentaba ya en 1977. El método fue posteriormente refinado en [Glover, 89; Glover, 90].

Se trata de un algoritmo metaheurístico que realiza una búsqueda secuencial escogiendo en cada iteración una única solución, y cuya característica fundamental es la memorización de los últimos movimientos realizados para alcanzar una determinada situación. Así pues, para la exploración del espacio de soluciones, se emplea información referida al proceso seguido para alcanzar la posición actual. Ésta es una de las metaheurísticas más citada y empleada en la resolución de problemas de optimización combinatoria [Blum et al., 03], habiendo sido utilizada con éxito en áreas como la planificación de la producción, problemas de asignación cuadrática, vehicle routing, telecomunicaciones, optimización gráfica, optimización de estructuras, localización, diversos tipos de *scheduling*, diseño de circuitos integrados, coloreado de gráficos, sistemas expertos, redes neuronales etc. [Glover et al., 95; Tabu Search Applications, 04]



Podría establecerse una analogía con la forma de actuar de un escalador en su búsqueda de la cumbre. Desde una determinada posición debe decidir la dirección del siguiente paso para alcanzar una posición aledaña a la actual que le permita ir avanzando hacia la cumbre. Esta elección estará basada en la experiencia obtenida en situaciones similares encontradas durante el ascenso. Llegado el momento puede ser necesario retroceder a la posición anterior puesto que una ruta determinada no ofrece posibilidades de continuar. Debe recordar los caminos y lugares ya visitados para no repetir dichos itinerarios, lo cual además de no ser eficiente, podría llevarle a realizar una trayectoria cíclica.

Así, la búsqueda tabú realiza una refinada búsqueda local basándose en una memoria de corto plazo para escapar de los óptimos locales, y evitar recorridos cíclicos. Para su implementación debe poderse pasar de una posición del espacio de soluciones a otra mediante variaciones de la codificación de la solución actual (*movimiento*). Las posiciones del espacio accesibles mediante un movimiento forman el *entorno* de la solución actual. Es necesario, asimismo, definir una función evaluadora de la calidad de los movimientos, que puede ser simplemente la función de coste o considerar factores diversos.

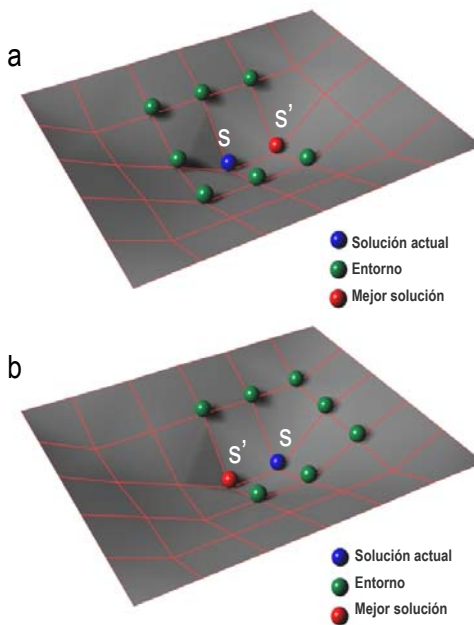


Figura 3.3: Ciclos en la búsqueda tabú; la lista tabú impide que las situaciones a y b se alternen indefinidamente.

A partir de una determinada solución  $s$  (generada de manera aleatoria o mediante alguna heurística), se define un conjunto de soluciones vecinas  $V(s)$  a las que se puede acceder desde  $s$  mediante una operación  $m$  denominada movimiento. Así pues  $V(s)$  se obtiene de aplicar a  $s$  todos los posibles movimientos. El algoritmo se desarrolla escogiendo en cada iteración un elemento  $s'$  del conjunto  $V(s)$  del entorno de la solución actual. La selección se realiza en función de la evaluación de cada una de las alternativas. Dado que  $s$  pertenecerá al entorno  $V(s')$  de la nueva solución, existe el riesgo de visitar una misma solución más de una vez, o de forma más general, de que se establezcan ciclos sin fin (Figura 3.3). Para evitar esto se dota al algoritmo de la capacidad de memorizar las

posiciones visitadas más recientemente mediante la utilización de una estructura en forma de lista circular (lista tabú) de tamaño  $L$ , impidiendo que éstas sean revisitadas, a menos que se cumplan determinadas condiciones (aspiraciones). El criterio de aspiración más sencillo es el conocido como *criterio del mejor costo*, en el que el movimiento hacia una solución es aceptado si su costo es mejor que el costo de la mejor solución obtenida hasta el momento. Para la actualización de la lista tabú se emplea habitualmente una estrategia FIFO, en la que en cada iteración los movimientos recientes van sustituyendo a aquellos que se han

realizado hace más de  $L$  iteraciones (Figura 3.4).

Tras varias iteraciones de este proceso, se intercalan fases de diferente naturaleza, que persiguen la diversificación e intensificación en la búsqueda de soluciones y que serán analizadas posteriormente. El número de iteraciones que se han de realizar antes de comenzar una fase de intensificación o diversificación, es un parámetro que permite definir si la evolución del algoritmo estará más influida por la memoria a corto plazo, o por las memorias a medio y largo plazo de dichas fases.

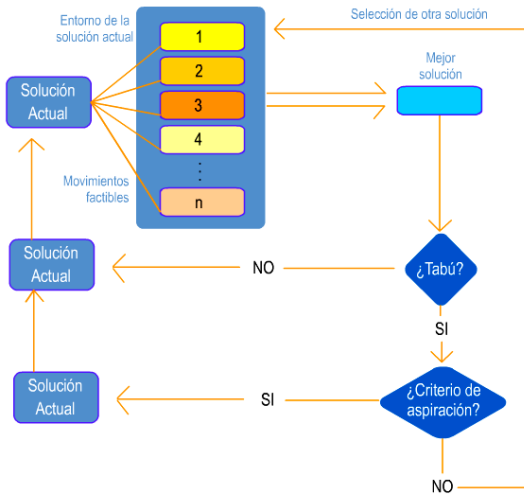


Figura 3.4: Diagrama de flujo de búsqueda tabú; memoria a corto plazo. Adaptado de [Youssef et al., 01].

Los criterios de parada más habitualmente aplicados al algoritmo son finalizar la búsqueda cuando se alcanza un número de iteraciones prefijado, o cuando se supera un número determinado de iteraciones sin que se produzca una mejora en la solución obtenida. Otro criterio de detención más elaborado, consiste en lanzar en paralelo diferentes instancias del algoritmo, comparando las mejores soluciones de cada uno tras un número prefijado de iteraciones. Si dos o más soluciones se encuentran entre las mejores obtenidas hasta el momento se detiene la ejecución.




Figura 3.5: Actualización de la lista tabú.

### 3.3.2 La lista tabú y los criterios de aspiración

La lista tabú es la denominada memoria a corto plazo del algoritmo. En ella se almacenan las soluciones visitadas recientemente impidiendo que se repitan los movimientos hacia ellas. En cada iteración se selecciona la mejor solución del entorno de la solución actual, pasando aquella a estar incluida en la lista tabú.

Manejar una lista tabú en la que se consignen soluciones completas puede resultar ineficiente y costoso si la codificación de las mismas es compleja, recurriéndose en este caso a almacenar

determinados **atributos** de la solución en lugar de la solución en sí. Esto supone, evidentemente, una generalización que produce cierta pérdida de información, que puede

provocar que soluciones no visitadas hasta el momento, y que comparten atributos con otras que sí lo han sido, sean incluidas en la lista tabú. Este problema puede solventarse con una adecuada definición de los criterios de aspiración, que permitan en determinados casos, aceptar una solución perteneciente a la lista tabú. El algoritmo generará y actualizará tantas listas tabú como atributos de las soluciones visitadas contemple.

En cada iteración realizada, la lista tabú (o listas en caso de considerar diversos atributos) es actualizada para incluir el nuevo movimiento. Dado que la lista tiene un tamaño limitado (*tenencia*), debe excluirse algún elemento de la misma para dar cabida al nuevo movimiento; de forma habitual se emplea una sustitución de tipo FIFO (aunque existen otras alternativas) en la que la solución actual sustituye a la solución que más tiempo lleva en la lista, perdiendo ésta su condición de tabú. Un atributo permanece en la lista  $t$  iteraciones, siendo  $t$  el tamaño de la lista tabú (Figura 3.5). Si nos encontramos en la iteración  $k$ , el atributo  $a(k)$  entra en la lista, saliendo de la misma  $a(p)$ , el atributo que entró en la iteración  $p$  ( $p=k-t+1$ ).

Glover [Glover, 90] define la lista tabú como:

$$T = \{s_h^{-1}; \forall h > k - t\}$$

donde  $s_h^{-1}$  designa el movimiento inverso al realizado en la iteración  $h$ .

Así, para la iteración  $k$  en la que se produce el movimiento  $s_k$ , el mecanismo de actualización de la lista sería denotado por:

donde “+” y “-” expresan las operaciones de añadir y eliminar elementos de la lista.

$$T = T - s_{k-t}^{-1} + s_k^{-1}$$

El tamaño de la lista tabú es fundamental en el buen desempeño del algoritmo. Un tamaño pequeño implica una memoria a más corto plazo, que permite una búsqueda intensiva en un área pequeña del espacio de soluciones. Un tamaño grande implica el estudio de regiones mayores, dado que el número de movimientos prohibidos en el entorno es mayor. Algunos autores emplean un tamaño de 7 para la lista tabú (sin que parezca haber una justificación clara para escoger este valor), otros  $(n)^{1/2}$  siendo  $n$  una medida del tamaño del problema [Andrés 2001]. En la aplicación del algoritmo a la resolución del problema cuadrático de asignación se emplean tamaños de la lista tabú comprendidos en el intervalo  $[0.9n, 1.1n]$  [Taillard, 91].

El tamaño de la lista puede ser variable adaptándose durante la búsqueda. El caso más simple es cambiar el tamaño de la lista periódicamente, dándole un valor comprendido dentro de un cierto intervalo. En otros casos se estudian las repeticiones de las soluciones, incrementando el tamaño de la lista si se dan muchas (es necesario una mayor diversificación) y disminuyéndolas si no se producen mejoras (es necesario una mayor intensificación).

Existen otros sistemas de lista de tamaño variable (cancellation sequence, reverse elimination method, moving gap...) y formas para definir el tamaño de la lista adecuado al problema en estudio. Cuando se empleen varias listas tabú para contener distintos atributos de las soluciones visitadas, Salhi [Salhi, 02] (y ya antes en [Glover, 89]) recomienda emplear

tenencias diferentes para cada una de ellas, adaptadas a las características de los atributos que contienen y en como influyen estos en las soluciones obtenidas.

Si se prohíben todos los movimientos incluidos en la lista tabú se evita de manera eficaz la entrada del algoritmo en ciclos de movimientos. Sin embargo, esto puede dar lugar a una restricción excesiva de la exploración que obstaculice la llegada a buenas soluciones. Esto es así cuando la lista tabú incluye atributos de las soluciones recorridas en lugar de la codificación de la propia solución. Una buena solución no visitada todavía, podría ser prohibida debido a que los atributos de dicha solución contemplados por el algoritmo, coinciden con los de otra solución ya visitada. Este problema puede ser solventado mediante una correcta definición de los criterios de aspiración.

Como se indicó en el apartado 3.3.1, el criterio de aspiración más sencillo es el conocido como criterio del *mejor costo*, en el que el movimiento hacia una solución tabú es aceptado si su costo es menor que el costo de la mejor solución obtenida hasta el momento  $C(\mathbf{s}^*)$ . Otro criterio posible es emplear funciones de aspiración  $F_a$ , aceptando una solución tabú  $\mathbf{s}$  cuando el valor de  $C(\mathbf{s})$  sea mejor que el de  $F_a(C(\mathbf{s}))$ . [Andrés, 01].

[Glover et al., 03] realizan una clasificación de los criterios de aspiración citando algunos ejemplos:

**Aspiración por defecto**

Llegado el caso en el que todos los movimientos posibles están clasificados como tabú, y ninguno ha superado algún otro criterio de aspiración, se selecciona el aspirante “menos tabú”, aquel que antes pierde su condición de tabú ante variaciones crecientes de las condiciones del problema (por ejemplo el número de iteración actual).

**Aspiración por objetivo**

	Aspiración de movimiento <sup>14</sup>	
	Forma global	Es el ya mencionado criterio del mejor costo, en el que el movimiento hacia una solución tabú es aceptado si su costo es mejor que el costo de la mejor solución obtenida hasta el momento
	Forma regional	Se subdivide el espacio de búsqueda en varias regiones $R_i$ . Llamemos $MCR_i$ al mejor coste encontrado en una solución perteneciente a la región $R_i$ . Sea $\mathbf{x}$ una solución candidata perteneciente una región $R_x$ , esta solución será aceptada si el coste de $\mathbf{x}$ es inferior a $MCR_x$ .

<sup>14</sup> Cuando se cumple una aspiración de movimiento queda revocada la condición de tabú de dicho movimiento.

Aspiración de atributo <sup>15</sup>	
Aspiración por dirección de búsqueda	Consideremos el atributo $e$ y su atributo inverso $\hat{e}$ . Si el movimiento más reciente conteniendo a $\hat{e}$ fue un movimiento de mejora, un movimiento candidato que contenga a $e$ satisfará el criterio de aspiración (hará a $e$ tabú-inactivo) si además su coste es inferior al de la solución actual. El movimiento puede seguir siendo tabú si además posee otros atributos tabú-activos.
Aspiración por influencia	Emplea el concepto de influencia, que mide el grado de cambio inducido en la estructura de la solución o en la factibilidad de la solución.

Tabla 3.1: Una clasificación de los criterios de aspiración. Adaptado de [Glover et al., 03].

En el caso del problema cuadrático de asignación, en el que el movimiento se define como el intercambio de la posición de dos actividades, Taillard propone aceptar el movimiento si las dos actividades no han ocupado las posiciones de destino en un número determinado de iteraciones. Este número será cercano a diez veces el tamaño del entorno (posibles soluciones alcanzables desde la actual, mediante el intercambio de la posición de un par de actividades de igual área o con frontera común, Figura 3.6).




Figura 3.6: Intercambio de dos actividades adyacentes.

### 3.3.3 Definición del entorno y creación de la lista de candidatos

El entorno de una solución  $\mathbf{V}(\mathbf{s})$  es el conjunto formado por todas las soluciones accesibles desde  $\mathbf{s}$  mediante un movimiento; evidentemente la estructura de  $\mathbf{V}(\mathbf{s})$  dependerá de la definición de movimiento. Por ejemplo, en el problema cuadrático de asignación se entiende movimiento como el intercambio de la posición de dos actividades (caso discreto), por lo tanto, el entorno estará comprendido por todas las posibles soluciones resultantes del intercambio de dos actividades. En el caso de un problema monoárea de  $n$  actividades, el entorno de una solución estaría formado por  $\frac{1}{2} \cdot n(n-1)$  soluciones, algunas de las cuales pueden estar incluidas en la lista tabú. Para el problema multiárea el cardinal del entorno es menor, debido a que no todos los intercambios de la posición de dos actividades son viables,

<sup>15</sup> En caso de cumplirse una aspiración de atributo, lo que pierde su condición de tabú es el atributo en cuestión, pudiendo el movimiento seguir siéndolo si ésta condición depende de otros atributos.

siendo sólo posibles si éstas poseen la misma área o son adyacentes (Figura 3.7).

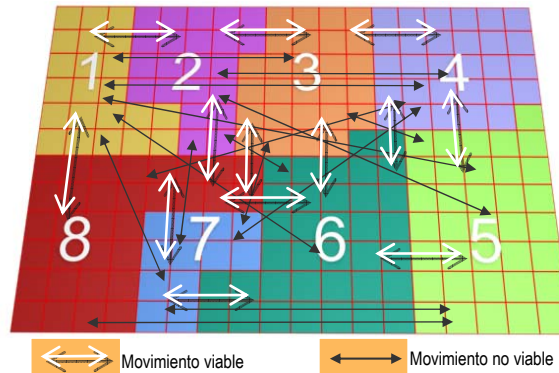


Figura 3.7: Entorno de una solución en el problema cuadrático de asignación multiárea.

El algoritmo debe evaluar cada una de las soluciones comprendidas en  $V(s)$  para escoger el mejor de los movimientos posibles, pudiendo resultar ésta una labor muy costosa si el conjunto es muy extenso. Por ejemplo, en el caso del problema cuadrático de asignación, la cardinalidad del entorno aumenta cuadráticamente con el número de actividades involucradas. Para solventar el problema se restringe la búsqueda a ciertos elementos del entorno que conformarán la *lista de candidatos* [Glover et al., 93].

La lista de candidatos puede formarse bajo diferentes criterios [Santamarina, 95], siendo el más sencillo restringir la lista a un número determinado de soluciones escogidas aleatoriamente. Este procedimiento es empleado habitualmente en las técnicas de optimización basadas en redes neuronales, en los que la lista de candidatos es formada mediante un muestreo estadístico aleatorio, en el que cada candidato es aceptado o rechazado según un test de aceptación.

Otros sistemas realizan dicha selección de una manera más sistemática. La técnica de **descomposición de movimientos** de Glover, crea subconjuntos de movimientos basados en atributos de la estructura del problema o de la solución actual, persiguiendo centrar la búsqueda en zonas en las que dichos atributos prometen buenos resultados, lo cual es una forma de intensificación de la búsqueda (ver apartado 3.3.4.1). La técnica de las **evaluaciones sucesivas** disminuye progresivamente el número de candidatos (mejorando simultáneamente su calidad), mediante la aplicación de sucesivas de reglas de filtrado en diferentes fases. La fase inicial incluye en la lista de candidatos a todos los movimientos posibles; las fases sucesivas aplican filtros sobre dicha lista, reteniendo los mejores movimientos de la fase precedente. Las **estrategias de desdoblamiento** son aplicables a movimientos interpretables como el intercambio de elementos entre diferentes grupos. Dado que dicho movimiento puede descomponerse en la eliminación de un elemento de un grupo, y la inclusión en otro, la selección se basaría en la búsqueda de la mejor eliminación y/o la mejor inclusión.

### 3.3.4 Tipos de memoria; estrategias de intensificación y diversificación

Las estructuras para el almacenamiento de información referida al proceso seguido por el algoritmo (memoria) pueden implementarse de diferentes maneras. Como se ha visto, en algunos casos se almacenan las soluciones visitadas al completo (memoria explícita), mientras que en otros, son determinados atributos de las soluciones los que quedan registrados en las estructuras de memoria (memoria por atributos).

La lista tabú es una forma de almacenamiento de la historia de búsqueda reciente, y es habitualmente asociada con una memoria de corto plazo, quedando el “tamaño” de dicho plazo definido por la tenencia de la lista (ver apartado 3.3.2). Esta memoria a corto plazo fomenta una exploración agresiva del entorno de la solución actual, buscando en cada movimiento la mejor alternativa posible que satisfaga ciertas restricciones. Sin embargo, es posible extraer información útil del proceso de búsqueda si se contempla éste a más largo plazo, dotando al algoritmo de una cierta capacidad de aprendizaje.

Ejemplos de este estilo serían las estructuras de memoria basadas en frecuencias, que complementan la información proporcionada por la memoria a corto plazo para la selección de movimientos de entre los candidatos. Las estructuras basadas en **frecuencia de residencia**, guían al algoritmo introduciendo incentivos y penalizaciones basados en el número de veces que determinados atributos han aparecido entre las soluciones visitadas; se supone que los atributos frecuentes entre las buenas soluciones son deseables en la solución final, y que los atributos que aparecen asiduamente entre las malas soluciones deben ser evitados.

Otro tipo de información de valor proporcionado por estructuras de memoria basadas en la frecuencia de residencia, es la que permite localizar atributos *fortalecidos/excluidos* [Glover et al., 03]. Si en una secuencia de soluciones que contiene tanto soluciones de alta como de baja calidad, un determinado atributo tiene una alta frecuencia de residencia, puede considerarse que dicho atributo está fortalecido y que se está restringiendo el espacio de búsqueda a zonas donde las soluciones poseen dicha cualidad. En aras de la diversidad puede resultar necesario desechar soluciones que posean dicho atributo. Por otra parte es posible dirigir la búsqueda hacia zonas del espacio en el que las soluciones posean atributos poco frecuentes entre las soluciones recorridas, realizando así una exploración de zonas poco frecuentadas.

Un tipo diferente de estructuras de memoria se basan en **frecuencias de transición**, almacenando información referida a la frecuencia con que cambian determinados atributos de las soluciones recorridas. Así, un atributo con una elevada frecuencia de transición puede ser considerado como poco influyente en la calidad de las soluciones.

Otras posibilidades son [Blum et al., 03]:

- las estructuras basadas en lo **reciente** (*recency-based memory*), que recuerdan cuál fue la iteración más reciente en la que apareció un determinado atributo
- las basadas en la **calidad**, que acumulan y extraen información de la historia de búsqueda para localizar características presentes en las buenas soluciones; este sistema es empleado también por otras metaheurísticas como las de

colonias de hormigas (ver apartado 3.5)

- las basadas en la **influencia**, que memorizan elecciones de candidatos realizadas durante la búsqueda que han resultado críticas en el transcurrir del proceso de exploración.

Así pues, al esquema básico del algoritmo basado en una memoria a corto plazo, se pueden añadir esquemas de memoria a plazo medio y largo, que permiten relanzar la búsqueda hacia otras partes del espacio cuando el ritmo de mejora de las soluciones decae.

### 3.3.4.1 El proceso de intensificación

Se denominan estrategias de intensificación a los procedimientos destinados a realizar una búsqueda más exhaustiva, de aquellas zonas del espacio cuyas soluciones poseen atributos frecuentes entre las mejores soluciones localizadas hasta el momento. Se pretende así, guiar la búsqueda hacia zonas prometedoras del campo de soluciones, no suficientemente exploradas en el proceso básico del algoritmo.




Figura 3.8: Estrategia de intensificación.

Las estrategias de intensificación se asocian con las estructuras de memoria a medio plazo, que conservan y comparan las mejores soluciones generadas (lista élite) durante un determinado número de iteraciones (periodo de prueba). Las características que se presentan frecuentemente en las soluciones son consideradas atributos regionales de buenas soluciones.

De manera alternativa es posible aplicar las estrategias de intensificación imponiendo restricciones al problema o la estructura de la solución que centralicen la búsqueda en determinadas partes del espacio.

En la aplicación de la búsqueda tabú al problema de asignación generalizada propuesta en [Díaz et al., 01], la intensificación se lleva a cabo mediante una memoria de medio plazo basada en frecuencia, implementada mediante una matriz en la que se almacena el número de veces que un trabajo ha sido asignado a un agente concreto. La fase de intensificación recupera la mejor solución encontrada hasta el momento, fijando en la misma aquellas asignaciones de trabajos a agentes, que aparecen en la matriz con una frecuencia de al menos un 85%, y dejando libres el resto. Dado que dichas asignaciones aparecen en la



mejor solución y, muy frecuentemente, en el resto, es de suponer que fijarlas servirá de guía hacia buenas soluciones y reducirá el tamaño del problema. En ese punto se recupera la fase de memoria a corto plazo sobre el problema reducido.

### 3.3.4.2 El proceso de diversificación

Ya se ha visto que las estrategias intensificadoras emplean la memoria de medio plazo, para extender la búsqueda a zonas del espacio en las que las soluciones reúnen características similares a las mejores encontradas durante la exploración. En contraposición, las estrategias diversificadoras permiten evitar la convergencia prematura del algoritmo en óptimos locales, dirigiendo la búsqueda hacia zonas del espacio poco exploradas.




Figura 3.9: Estrategia de diversificación.

La memoria a largo plazo recopila información sobre las soluciones visitadas hasta un momento determinado, penalizando aquellos atributos de las nuevas soluciones que se han dado frecuentemente en aquellas y favoreciendo la aparición de otros poco estudiados. Este es un proceso similar a establecer una lista tabú que se activa periódicamente para redirigir la búsqueda.

Como ejemplo de implementación, Laguna y Glover [Andrés, 01] proponen penalizar la inclusión de atributos frecuentes hasta el momento en las nuevas soluciones, en función de la frecuencia relativa de dicho atributo. Dado un movimiento desde la solución  $i$  hacia la solución  $j$  con coste  $cm(i,j)$ , se define una función penalizadora:

$$P_m(i,j) = cm(i,j) \pm \alpha \cdot \text{frecuencia}(i,j)$$

expresión en la que  $(\pm)$  dependerá de si se está minimizando o maximizando el coste y  $\alpha$  es una constante a determinar de manera experimental.

Este mecanismo se pone en marcha si la tasa de obtención de nuevas soluciones cae por debajo de un cierto umbral.

En [Andrés et al., 98] si el hallazgo de nuevas buenas soluciones se vuelve lento, y durante un número concreto de iteraciones no aparece ninguna, se aumenta la tenencia de la lista tabú, provocando una restricción de la búsqueda en las zonas cercanas y fomentando el salto hacia zonas alejadas del punto actual.

En la aplicación de la búsqueda tabú al problema de asignación generalizada propuesta en [Díaz et al., 01], la diversificación se lleva a cabo mediante la misma matriz de frecuencias de aparición empleada para la intensificación (ver apartado 3.3.4.1), en la que se almacena el número de veces que un trabajo ha sido asignado a un agente concreto. Durante la diversificación, el coste de cada movimiento es penalizado en función de la frecuencia de aparición de las asignaciones que contiene.

### 3.3.4.3 Path Relinking y Tunneling

Las estrategias de intensificación y diversificación son a veces combinadas en el llamado *path relinking*. Esta técnica explora paso a paso, la trayectoria más corta entre dos buenas soluciones ya obtenidas, recomenzando la búsqueda desde alguna de las soluciones encontradas en el camino. Esto permite salvar zonas intermedias en las que las soluciones no son factibles (tunneling).

Si las soluciones de inicio y final de la trayectoria son similares, se estaría forzando un proceso de intensificación (Figura 3.10); por el contrario, escoger como soluciones de inicio y final para el *path relinking* soluciones desemejantes, es asimilable a un proceso de diversificación (Figura 3.11).

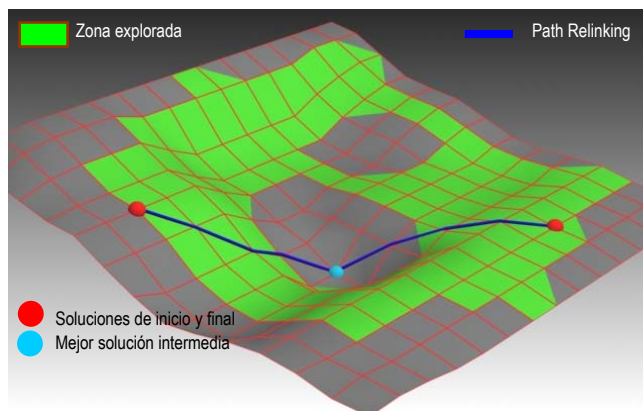


Figura 3.10: Path Relinking en proceso de intensificación.




Figura 3.11: Path Relinking en proceso de diversificación.

### 3.3.4.4 Oscilación estratégica

La oscilación estratégica permite al algoritmo avanzar sobre zonas no factibles del espacio de soluciones, para obligarle posteriormente a regresar a zonas factibles. En la evolución normal del algoritmo, éste puede llegar a la frontera con una zona no factible, donde habitualmente el algoritmo se detendría. La oscilación estratégica modifica la definición del entorno, o bien cambia los criterios de evaluación para seleccionar los movimientos de tal manera que pueda avanzar sobre la zona no factible. Durante un cierto número de iteraciones se permite al algoritmo evolucionar por esta zona, hasta que se le obliga a regresar al espacio factible. Los acercamientos y cruces de la frontera se repiten desde diferentes direcciones dando lugar a la denominada oscilación estratégica. Los procedimientos tabú estándar evitan la posibilidad de recorrer varias veces una trayectoria.

### 3.3.4.5 Los algoritmos tabú con umbral

El algoritmo tabú con umbral [Glover, 91] es una simplificación del algoritmo tabú, que se caracteriza por prescindir de las estructuras de memoria. La exploración reiterada se evita introduciendo criterios probabilísticos en la selección de los movimientos a realizar.

Existen en este algoritmo dos fases diferenciadas. La primera es una fase de intensificación en la que únicamente se admiten soluciones que mejoren la solución actual, lo cual conduce a la obtención de un óptimo local. Posteriormente en una fase de diversificación o mezcla, se admiten soluciones que ofrecen peores valores de la función objetivo (además, por supuesto, de las que mejoran la mejor solución actual), logrando de esta manera escapar del óptimo local explorando nuevas zonas del espacio de soluciones.

El conjunto de movimientos posibles permite, en principio, abarcar todo el espacio de soluciones. Sin embargo, en esta variante del algoritmo, se divide este conjunto en bloques o subconjuntos de movimientos que pueden ser usados en cualquiera de las fases antes mencionadas. Mediante un procedimiento probabilístico (que puede ser diferente en cada fase) se selecciona uno de los subconjuntos generados. En la primera fase se exploran los bloques escogidos aceptando soluciones que mejoren la mejor solución actual, mientras que en la diversificación se acepta el mejor movimiento dentro de cada bloque,

independientemente de si mejora o no la solución actual. Los bloques explorados no vuelven a ser visitados.

En ambas fases se guía la búsqueda hacia el movimiento que conduzca a la mejor solución mediante listas de candidatos, permitiendo acelerar el proceso de optimización.

### **3.3.5 Aplicación de la búsqueda tabú a la distribución en planta**

Estudios y aplicaciones de algoritmos de búsqueda tabú en la resolución del problema de la distribución en planta puede encontrarse en [Skorin-Kopov, 90; Taillard, 91; Chakrapani et al., 93; Skorin-Kopov, 94; Chiang et al., 96; Díaz et al., 01; Martins et al., 03; Misevicius, 03a; Cavin et al., 04; Drezner, 05; Wen-Hsing, 05].

## **3.4. Computación evolutiva**

### **3.4.1 Introducción**

La computación evolutiva plantea los problemas complejos de búsqueda y optimización bajo un enfoque evolutivo, basado inicialmente y a grandes rasgos, en la teoría evolucionista del desarrollo de las especies naturales elaborada por Darwin. La computación evolutiva es implementada en los denominados algoritmos evolutivos. De forma general, estos algoritmos realizan una búsqueda estocástica guiada basándose en la evolución reiterada de un conjunto de estructuras, y la selección de las más adecuadas en cada ciclo. Estas técnicas pueden ser clasificadas en tres categorías principales: los algoritmos genéticos (AG), las estrategias evolutivas (EE) y la programación evolutiva (PE). Algunos autores añaden a estas categorías los sistemas clasificadores genéticos (SCG) empleados habitualmente en la inferencia de reglas y patrones.

A pesar de sus similitudes, cada uno de estos procedimientos fueron desarrollados de manera independiente, no existiendo contacto formal entre los investigadores de cada área hasta 1990 [Fogel et al., 94]. Todas las técnicas incluidas bajo la denominación de computación evolutiva se basan en un esquema general común (Figura 3.12). El punto de partida es un conjunto de soluciones al problema generadas de manera aleatoria (población inicial). Esta población es sometida a una serie de transformaciones que dan lugar a una nueva población de soluciones. Se valora la adaptabilidad al medio de cada una de las soluciones de dicha población mediante una función de transformación (función objetivo). A partir de la valoración de los individuos de la población, e incluyendo cierto grado de aleatoriedad, se favorece a los individuos mejor dotados en un proceso de selección para conformar la siguiente generación. Este proceso es repetido a la espera de que, tras cierto número de ciclos (generaciones), los individuos de la población hayan evolucionado hacia una mayor adaptación al medio.

Así, los algoritmos evolutivos tendrán en común:

- un conjunto de soluciones debidamente codificadas (individuos) formando una población
- un procedimiento de transformación para la construcción de nuevas soluciones

a partir de las soluciones de la población anterior

- una función evaluadora de la bondad de las soluciones que forman parte de la población
- un mecanismo de selección de individuos en función de su adaptación al medio.

Las diferencias fundamentales entre cada una de las técnicas radican en los tipos de alteraciones que se realizan sobre las soluciones para obtener nuevos individuos, y en los métodos empleados para la selección de los supervivientes y los reproductores.

```

Begin;
P[0]:= Inicialización_de_la_población( );
Bondad_P[0]:= Evaluación (P[0]);
G:=0;
Until (condición_de_terminación) do
    Begin;
        Paux[G]:=Selección_de_reproductores (P[G], Bondad_P[G]);
        Paux[G]:=Transformación (Paux[G]);
        Bondad_Paux[G]:= Evaluación (Paux[G]);
        P[G]:=Selección_de_supervivientes (P[G], Paux[G], Bondad_P[G], Bondad_Paux[G]);
        Bondad_P[G]:= Evaluación (P[G]);
    End;
End;
    
```

Figura 3.12: Esquema general de un Algoritmo Evolutivo.

La naturaleza del problema que se pretende resolver determinará el tipo de técnica evolucionista más adecuada. Los algoritmos evolutivos han sido aplicados a problemas de naturaleza muy diferente: robótica, tratamiento de imágenes, inteligencia artificial, problemas de asignación, etc. [Goldberg, 89a]

Antes de comenzar con una explicación más detallada de cada una de las técnicas de la computación evolutiva, se hace necesario realizar alguna consideración previa sobre el evolucionismo como proceso de optimización.

### 3.4.2 Dualidad genotipo / fenotipo

El genotipo de un individuo designa la constitución genética completa (expresa o latente) de un individuo, es decir, el genotipo es la información contenida en los alelos de los genes del individuo. Por otra parte el fenotipo es el conjunto de rasgos o características visibles del individuo. Es de algún modo la expresión o el resultado de la constitución genética de ese ser y está determinado por los genes y por las condiciones ambientales en las que se desarrolla<sup>16</sup>. Así pues, los rasgos fenotípicos no son necesariamente consecuencia exclusiva de la carga genética del individuo, sino que el desarrollo y la conducta de éste frente al

<sup>16</sup> Fuente: Glosario de Términos Genéticos. National Human Genome Research Institute. <http://www.genome.gov/sglossary.cfm>

medio exterior está condicionada por el propio medio (epigénesis<sup>17</sup>) [Atmar, 94] y por el aprendizaje sociogenético y ontogenético del individuo y del grupo a lo largo de su existencia.

Por otra parte, fenómenos como la pleitropía<sup>18</sup> y la poligenia<sup>19</sup> impiden la existencia de una relación biunívoca entre la carga genética del individuo y los caracteres en que ésta se expresa (Figura 3.13). Así pues, diferentes estructuras genéticas pueden dar lugar a conductas similares, mientras que diferentes conductas pueden ser la expresión de idénticas estructuras genéticas.

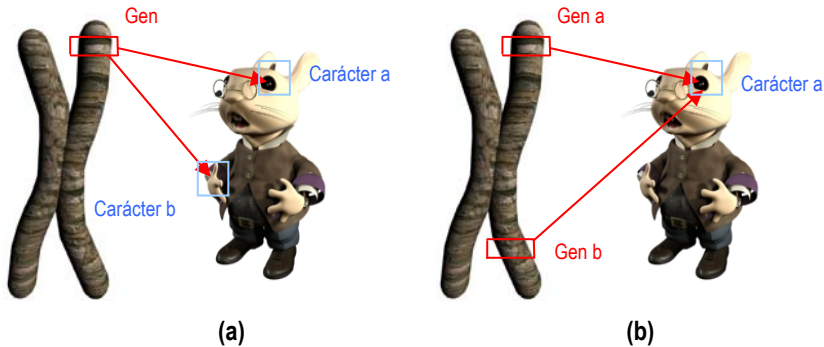


Figura 3.13: Pleitropía (a) y poligenia (b).

La adaptabilidad de un individuo al medio en que se desarrolla, está condicionada por la forma en la que se expresa su carga genética, es decir, su fenotipo, y no existe una relación directa entre el código genético y el comportamiento desarrollado; la selección natural actúa directamente sólo sobre la base de los comportamientos expresados de los individuos y las especies, no sobre su genotipo [Mayr, 88].

Llamando **G** al espacio de todas las posibles configuraciones genéticas de un individuo (espacio de los genotipos), y **F** al de los posibles fenotipos que es viable desarrollar a partir del espacio de genotipos **G** en un medio externo concreto, es posible establecer gráficamente la relación entre ambos [Santamarina, 95] (Figura 3.14).

Cada punto del espacio (**g**) de los genotipos representa la estructura genética de un determinado individuo, al cual puede hacersele corresponder un punto del espacio (**f**) de los fenotipos. El fenotipo es una función no lineal compleja de la interacción entre las estructuras genéticas subyacentes del individuo, y las condiciones ambientales actuales [Fogel, 94]. Llamando  $\mu$  a la función que mide la adaptación del individuo al medio, podemos establecer una relación entre cada punto del espacio de los fenotipos (**f**) y la medida de dicha adaptación  $\mu(\mathbf{f})$ . Representando gráficamente el conjunto imagen de dicha correspondencia,

<sup>17</sup> Teoría desarrollada por William Harvey (1578-1657), médico inglés, en la que el desarrollo orgánico era visto como la producción de forma acumulativa de estructuras complejas a partir de un material inicialmente homogéneo. Se basa en las ideas desarrolladas por Aristóteles.

<sup>18</sup> La pleitropía es un fenómeno por el cual un solo gen puede estar relacionado e influir en más de un carácter fenotípico.

<sup>19</sup> La poligenia es un fenómeno que implica a varios genes en la expresión de una única conducta fenotípica.

obtendremos la topografía de la función "nivel de adaptación de los individuos al medio" (lo que Write (1936) denominaba "topología adaptativa" [Fogel, 94]). Los algoritmos evolutivos realizan una búsqueda dirigida del máximo global de la función de adaptación recorriendo dicha topografía.

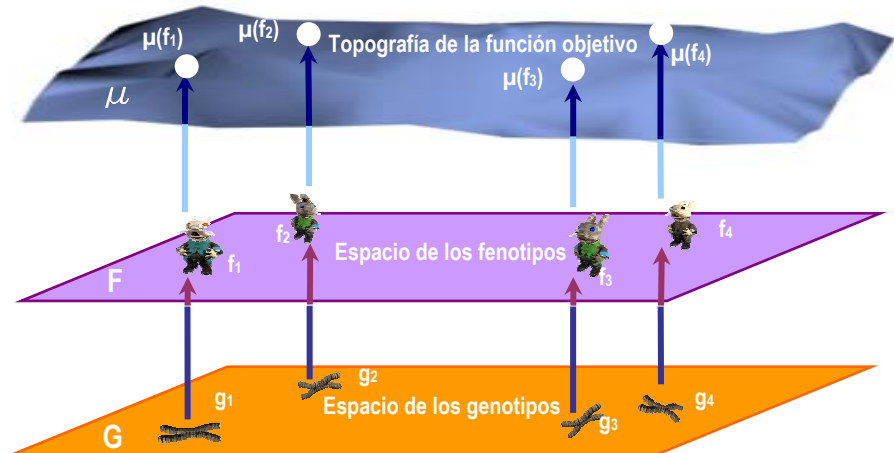


Figura 3.14: Relación entre el espacio de los genotipos y el de los fenotipos. Topografía de la función objetivo.

### 3.4.3 Técnicas de computación evolutiva

#### 3.4.3.1 Algoritmos genéticos

Dentro de las técnicas de computación evolutiva, los algoritmos genéticos [Holland, 75] ocupan un lugar preeminente debido, fundamentalmente, a los siguientes motivos [Pérez, 04]:

- las ideas fundamentales del enfoque evolutivo están recogidas de una manera natural en dicha técnica
- son flexibles y adaptables a una gran cantidad de problemas diferentes pertenecientes a distintas áreas y permiten ser combinados con otras técnicas no necesariamente pertenecientes a la computación evolutiva (hibridación)
- dentro de las técnicas de computación evolutiva de los algoritmos genéticos son los que poseen una mayor base teórica
- poseen una gran versatilidad pues son los que necesitan menos conocimiento específico del problema para su resolución
- es posible implantarlos en ordenadores con capacidades medias obteniendo resultados muy aceptables

dentro de las técnicas metaheurísticas son, con diferencia, las más empleadas [Jones et

al., 02], existiendo multitud de estudios previos referidos a su empleo, parametrización e implantación, así como herramientas informáticas genéricas adaptables a diferentes problemas [Whitley et al., 88; Grefenstette, 90; Smith et al., 91; Pérez, 04].

Pérez proporciona la siguiente definición de algoritmo genético:

*“Los algoritmos genéticos son métodos estocásticos de búsqueda ciega de soluciones cuasi-óptimas. En ellos se mantiene una población que representa un conjunto de posibles soluciones que son sometidas a ciertas transformaciones con las que se trata de obtener nuevos candidatos, y a un proceso de selección sesgado en favor de los mejores candidatos.”*

Se dice que los algoritmos genéticos son métodos de búsqueda ciega debido a que éstos no disponen de más información del problema a resolver que aquella obtenida de la función objetivo empleada. Esta característica junto con el hecho de que la búsqueda se realiza simultáneamente sobre un conjunto poblacional más o menos amplio, hacen de los algoritmos genéticos una técnica robusta de resolución de problemas.

A esto contribuye el denominado *paralelismo implícito* de los algoritmos genéticos; debido al tipo de codificación empleado (generalmente binario), del procesamiento de cada individuo (del código de cada individuo) se obtiene información sobre todos los individuos cuyos códigos siguen patrones similares.

El proceso comienza, como en el resto de las técnicas de computación evolutiva, generando un conjunto de soluciones al problema de manera aleatoria. Cada una de estas soluciones está codificada mediante una cadena de longitud finita (cuyo contenido son habitualmente valores binarios) que la hace corresponder con un punto del dominio del problema. Estableciendo la analogía natural, dicha cadena sería un cromosoma y cada elemento de la cadena un gen.

La transformación de los individuos de cada generación se lleva a cabo mediante la definición de una serie de operadores genéticos. Los más habituales son la selección, el cruce, y la mutación, aunque existen otros tipos y múltiples variantes de los anteriores (mutación no uniforme, mutación no estacionaria, cruces con adaptación, cruces solitarios, cruces anulares...). Mediante la aplicación de estos operadores sobre los cromosomas de diferentes miembros de la población, es posible obtener individuos que hereden las características de sus predecesores.

Para ello se deberán escoger previamente los individuos que participarán de cada uno de los operadores genéticos, y aquellos que sobrevivirán y pasarán a la siguiente generación. El mecanismo de muestreo empleado puede ser muy diverso, yendo desde la selección directa de los mejores individuos (aquellos cuyos caracteres los hacen más adaptados al medio), a muestreos estocásticos de diversos tipos (por sorteo, por ruleta, por torneos, por restos...).

El proceso se repite hasta que algún individuo alcanza un valor prefijado del nivel de adaptación, el algoritmo converge [Goldberg, 89a; Rudolph, 94; Srinivas et al., 94a], o simplemente, hasta que el número de interacciones llega un valor determinado.

Los algoritmos genéticos serán tratados en profundidad en el siguiente capítulo de este trabajo.



#### 3.4.3.1.1 Programas de evolución

Aunque algunos autores proponen a los programas de evolución como una categoría particular dentro de la computación evolutiva [Michalewicz, 92; Pérez, 04; Romero et al., 04], la mayor parte coincide en incluirlos como una variante de los algoritmos genéticos [Spears et al., 93; Fogel, 94; Santamarina, 95].

Los algoritmos genéticos requieren una mínima cantidad de información y conocimiento específico sobre el problema a resolver, logrando de esta manera una gran generalidad y una importante reducción del esfuerzo de implantación para cada problema concreto. Ésta generalidad es obtenida, entre otras causas, por la exigencia de representar los individuos a través de cadenas binarias (existiendo sólo dos posibles alelos para cada gen) cumpliendo el principio del alfabeto de símbolos mínimo, lo cual maximiza, además, el grado de paralelismo implícito. Esta forma de representación limitada supone un grave inconveniente para resolver problemas en los que se deban considerar restricciones importantes en el espacio de búsqueda. Este es el caso de gran parte de los problemas de ingeniería en los que se requiera gran precisión. La representación binaria puede, en estos casos, originar individuos de gran tamaño que requieren grandes capacidades de cómputo y almacenamiento. Por otra parte, individuos representados por cadenas extremadamente largas, hacen aumentar el tamaño del espacio de posibles soluciones, lo que según Zbigniew Michalewicz [Michalewicz, 92] hace disminuir el rendimiento de los algoritmos genéticos.

Este autor propuso una representación alternativa (matrices, listas, árboles, vectores de reales...) más cercana al dominio del problema y de mayor significación. Por otra parte, propone que los operadores genéticos sean adaptados al dominio de búsqueda y en general al problema. Se trata de lograr operadores genéticos cerrados, es decir, que el resultado de aplicar dichos operadores sea siempre un individuo factible. Así pues, bastaría con generar una población inicial factible para que el algoritmo permaneciera siempre en el dominio del problema. Estas modificaciones proporcionan cierto conocimiento específico al algoritmo, que aunque disminuyen su generalidad respecto a los algoritmos genéticos, aumentan su eficiencia en la consideración de restricciones importantes y en la resolución de problemas de optimización numérica.

Los programas de evolución parecen obtener buenos resultados comparables con otros métodos con un carácter marcadamente heurístico. Al parecer, la pérdida de paralelismo implícito, consecuencia de la violación del principio del alfabeto de símbolos mínimo (que reduce la variedad de los esquemas), queda compensada por la inclusión de información en la codificación de los individuos y por el empleo de operadores genéticos sensibles al problema.

#### 3.4.3.2 Estrategias evolutivas

Las estrategias evolutivas fueron desarrolladas por Rechenberg [Rechenberg, 73] como procedimientos estocásticos de optimización paramétrica de paso variable adaptativo (dadas estas características podrían encontrarse ciertas analogías con el recocido simulado), diseñadas específicamente para resolver problemas de optimización paramétrica [Atmar, 94; Fogel, 94; Fogel et al., 94; Nissen, 94].

Las estrategias evolutivas **simples** (o de dos miembros) hacen evolucionar a un único

individuo y emplean la mutación como único operador genético. El único individuo será representado mediante dos cromosomas (vectores reales), uno de los cuales representa un punto del dominio de búsqueda y el otro es un vector de desviaciones empleado para realizar la mutación. Dado que existe un único individuo no tiene sentido el operador selección, y el criterio de reemplazo se limita a que el descendiente sustituye al progenitor si aquél es mejor que éste.

Las estrategias evolutivas **múltiples** surgen como respuesta a la tendencia de las estrategias simples a converger prematuramente hacia sub-óptimos locales [Schwefel, 81]. Este problema se afronta mediante la búsqueda múltiple y la adecuada discriminación de los descendientes. Para ello se hace necesario introducir el operador selección y el operador cruce, que permiten dicha discriminación y la recombinación de los cromosomas de diferentes individuos. A diferencia de los algoritmos genéticos el criterio de reemplazo es puramente determinista.

Las diferencias fundamentales entre algoritmos genéticos y estrategias evolutivas podrían resumirse en:

- las estrategias evolutivas requieren de un mayor conocimiento específico del problema a resolver que los algoritmos genéticos
- los algoritmos genéticos realizan una búsqueda global mientras que las estrategias evolutivas obtienen mejores resultados en búsquedas localizadas
- mientras que el operador genético clave en un algoritmo genético es el que permite la recombinación (cruce), en las estrategias evolutivas este papel lo asumen los operadores de alteración (mutación)
- el procedimiento de reemplazo en los algoritmos genéticos es estocástico, mientras que las estrategias evolutivas utilizan criterios deterministas (se escogen los mejores individuos de la población)
- mientras que los algoritmos genéticos son de adecuada aplicación en la optimización de atributos, las estrategias evolutivas se emplean preferentemente en la optimización paramétrica.

Es posible encontrar diferencias también en la analogía natural de cada una de las técnicas. Mientras que en los algoritmos genéticos cada elemento de la cadena empleada para codificar un individuo representa un gen (siendo la cadena un cromosoma), en las estrategias evolutivas cada elemento de la cadena representa un carácter (un rasgo fenotípico). En el primer caso el procedimiento de optimización se lleva a cabo actuando sobre el genotipo, mientras que el segundo se actúa directamente sobre el fenotipo.

### 3.4.3.3 Programación evolutiva

La programación evolutiva [Fogel et al., 66] nace como uno de los primeros intentos de dotar de inteligencia a las máquinas empleando analogías evolutivas, y encontró en sus inicios algunas reticencias por parte de la comunidad científica. La intención de Fogel era que las máquinas pudieran conocer su entorno, prever los cambios y reaccionar adecuadamente ante estos.

El problema fue planteado por Fogel codificando el entorno como una secuencia de símbolos tomados de un alfabeto finito. El algoritmo opera sobre esa secuencia para producir un símbolo de salida que anticipe el siguiente símbolo a aparecer en el entorno. La representación de dicho comportamiento se llevó a cabo mediante máquinas de estados finitos (o autómatas finitos), que consiste en un conjunto de estados y reglas de transición entre ellos, de forma que, al recibir una entrada, cambia o no de estado y produce una salida.

La programación evolutiva basada en autómatas finitos opera de la siguiente manera [Fogel, 94]:

- se crea una población inicial de autómatas de manera aleatoria
- se proporciona a dicha población una cadena de símbolos que codifican las variaciones del entorno observadas hasta el momento
- ante cada símbolo de entrada, las máquinas suministran un símbolo de salida que es comparado con el siguiente símbolo de la cadena proporcionada, siendo valorado cada individuo en función de la proximidad de la predicción a la realidad
- nuevos autómatas son creados a partir de la mutación aleatoria de los anteriores, siendo evaluados en su comportamiento ante la misma cadena representativa del entorno que sus progenitores
- se escoge a los mejores individuos de entre los autómatas originales y aquellos creados por mutación para formar parte de la nueva población que mantendrá un tamaño constante
- los dos últimos pasos son repetidos hasta que aparece un nuevo símbolo en la cadena representativa del entorno que aún no ha sido experimentado por los autómatas, momento en el que se reinicia el proceso

En la codificación de los individuos, cada gen podría interpretarse como una terna en la que se indica: el estado de partida, la cadena reconocida procedente del entorno y el estado al que se llegará partiendo del estado original y ante dicho entorno. En definitiva, cada gen es una regla que especifica las condiciones (cadena reconocida) que se deben cumplir para llegar a un estado (estado destino) suponiendo que la máquina se encuentra en un cierto estado (estado origen).

Aunque el procedimiento es análogo al resto de las técnicas evolucionistas, pueden remarcarse algunas diferencias respecto a la analogía natural. La codificación empleada difícilmente permite asociar cada cadena con un individuo, si no que más bien, representaría a un conjunto de individuos con características comunes dotados de aislamiento reproductivo (especie). El cruce aplicado a individuos de diferentes especies da lugar a individuos inviábiles, de hecho, no existe como tal en ésta técnica el operador de cruzamiento, siendo la adaptación de cada especie al medio mediante la mutación de sus caracteres, la que rige el proceso de optimización.

#### **3.4.3.4 Otras técnicas**

Aunque las categorías antes descritas son los paradigmas de la computación evolutiva,

existen otras muchas técnicas clasificables como tales. Éstas surgen habitualmente por el refinamiento del comportamiento de los algoritmos en aspectos concretos, por la introducción de modificaciones que aportan al algoritmo conocimiento específico para la resolución de problemas en diversas áreas, por el empleo de otro tipo de analogías naturales o por la combinación de diferentes técnicas, heurísticas o no, dando lugar a algoritmos híbridos. Ejemplos de lo dicho son los algoritmos meméticos, la evolución diferencial o la programación genética.

Los **algoritmos meméticos** combinan conceptos y estrategias de diferentes metaheurísticas para intentar aunar las ventajas de las mismas. Emplean el concepto de transmisión memética<sup>20</sup> en una evolución de tipo poblacional combinada con mejoras individualizadas de las soluciones. Introducen el concepto de metaoperador, que modifica la forma de proceder del operador mutación, en función de aquellas actuaciones que mejores resultados previos han ofrecido. Estos metaoperadores operan como optimizadores locales.

La **evolución diferencial** es una variante relativamente simple de los algoritmos genéticos empleada para el modelado de sistemas. Emplea operadores de recombinación y mutación, teniendo este último operador la capacidad de auto-adaptarse durante la evolución de la población.

La **programación genética** tiene la particularidad de no tratar de resolver un problema de forma directa si no de encontrar la manera más sencilla de resolverlo. En este caso los individuos codificados (mediante árboles de análisis) son algoritmos o programas que resuelven dicho problema. La capacidad y eficiencia de cada individuo en la resolución determinará sus posibilidades de transmitir su carga genética. Los operadores empleados están adaptados a la forma de codificación empleada.

Por último, cabe destacar la tendencia actual hacia la paralelización en la ejecución de los algoritmos evolutivos. Es posible la ejecución descentralizada de los algoritmos debido a que en la aplicación de los operadores interviene un número limitado de individuos (habitualmente uno en la mutación y dos en el cruce), y a que la evaluación se realiza individuo a individuo de manera independiente al resto de la población. La más sencilla de las posibilidades es que varios procesadores compartan las tareas de evaluación (habitualmente las más intensivas en empleo de recursos). La mayor parte de las tareas se realizan en un único procesador que tras cada evolución envía los individuos al resto de máquinas para ser evaluados. Otras estructuras más complejas y eficientes dividen a la población (formando *islas* o *demes*) en diferentes equipos de cálculo que, cada cierto número de generaciones, se intercambian individuos (migración) [Tam et al., 98].

### **3.5. Colonias de hormigas**

Las hormigas son capaces de encontrar el camino más corto desde el hormiguero hasta una fuente de comida sin necesidad de referencias visuales. Son capaces, además, de

---

<sup>20</sup> El término memes fue acuñado por Richard Dawkins como analogía de genes en 1976 en su libro "The Selfish Gene". En esencia los memes son ideas que evolucionan de acuerdo a los mismos principios que gobiernan la evolución biológica; son conocimiento adquirido, cultura, comportamientos, formas de actuar, que son transmitidos entre individuos por imitación.

adaptarse a cambios en el entorno que les obligan a modificar las rutas preestablecidas; la aparición de un nuevo obstáculo en su camino es ejemplo de ello. El mecanismo empleado por las hormigas para realizar dichas actividades esta basado en el seguimiento de rastros de feromonas<sup>21</sup>.

El movimiento de una hormiga de manera individual se realiza de forma aleatoria. Al topár con un obstáculo en su camino elige para continuar cualquiera de las posibilidades sin un criterio definido (Figura 3.15 a). Durante el recorrido deja en el camino un rastro de feromonas cuya intensidad será inversamente proporcional a la distancia desde el hormiguero, dado que la velocidad de desplazamiento es prácticamente constante. Así, el rastro será más intenso en el camino más corto (Figura 3.15 b). A partir de ese punto el resto de hormigas seguirán con una mayor probabilidad el camino más corto hacia el objetivo marcado con mayor intensidad por la feromona (Figura 3.15 c).

Mediante una analogía con dicho comportamiento de las hormigas, Marco Dorigo presentó en su tesis doctoral [Dorigo , 92] un algoritmo basado en agentes (hormigas) que cooperan entre sí para obtener la solución a un problema intercambiando sus experiencias. En los sistemas reales esa memoria distribuida está representada por el rastro de feromonas que marca el camino a seguir. Si un camino resulta interesante se incrementa la cantidad de feromona. En los sistemas artificiales se modeliza mediante el aumento de la probabilidad de elegir un elemento en la construcción de la solución.

Los algoritmos de colonias de hormigas han sido aplicados a diversos ámbitos, entre los cuales se encuentran el problema del viajante de negocios [Dorigo et al., 97; Dorigo et al., 97], la secuenciación de la producción [Andrés, 01] o el problema cuadrático de asignación [Maniezzo et al., 95; Colomi et al., 96].

Como ejemplo, en [Colomi et al., 92] se aplica el algoritmo al problema del viajante de negocios. Para ello, se define el número de agentes (hormigas) que participarán en la búsqueda ( $h$ ), el coeficiente de evaporación  $\rho$  que marca el ritmo con el que desaparecerá la feromona depositada por los agentes en sus recorridos, la intensidad inicial de las trayectorias (feromona inicial depositada en las trayectorias)  $\tau_{ij}(t)$ , y el número de hormigas que parten de cada ciudad  $h_i(0)$ .

Cada hormiga construye un recorrido haciendo variar la intensidad de su trayectoria de acuerdo a la expresión:

$$\tau_{ij}(t + 1) = \rho \cdot \tau_{ij}(t) + \Delta \tau_{ij}(t, t + 1)$$

en la que  $\tau_{ij}(t)$  es la intensidad de la trayectoria entre las ciudades  $i$  y  $j$  en el instante  $t$ , y  $\Delta \tau_{ij}(t, t+1)$  es el aumento de la intensidad entre las ciudades  $i$  y  $j$  definido como la suma de los aumentos de intensidad para los  $h$  agentes u hormigas definidos. Este proceso se repite

---

<sup>21</sup> Las feromonas son sustancias químicas producidas por las glándulas sexuales de algunos animales (de forma destacable en los insectos) para atraer al individuo del otro sexo. La palabra feromona ha derivado para referirse a todo tipo de hormonas de atracción sexual, cuando en realidad las feromonas son un tipo de hormona de atracción específica producida por las hembras de muchas especies de animales, incluyendo a los seres humanos.

durante un número de ciclos determinado.

Para calcular el aumento de la intensidad del recorrido individual de cada hormiga, Marco Dorigo y sus colaboradores propusieron tres posibilidades [Dorigo et al., 97] que se diferencian en el momento y la forma de actualizar una matriz de intensidades [Dorigo et al., 96].

La primera propuesta se denomina *Ant-density* y en ella se realiza una actualización constante de la intensidad en el recorrido de la hormiga según la expresión:

$$\Delta^k \tau_{ij}(t, t + 1) = \begin{cases} Q_1 & \text{si la hormiga } k \text{ viaja desde } i \text{ a } j \text{ entre } t \text{ y } t + 1 \\ 0 & \text{en cualquier otro caso} \end{cases}$$

En la segunda propuesta, llamada *Ant-quantity*, la actualización se realiza de manera proporcional inversa a la distancia recorrida entre dos

$$\Delta^k \tau_{ij}(t, t + 1) = \begin{cases} \frac{Q_2}{d_{ij}} & \text{si la hormiga } k \text{ viaja desde } i \text{ a } j \text{ entre } t \text{ y } t + 1 \\ 0 & \text{en cualquier otro caso} \end{cases}$$

ciudades:

Por último, en la denominada *Ant-cycle*, la actualización es inversamente proporcional al trayecto completo realizado por la hormiga:

$$\Delta^k \tau_{ij}(t, t + 1) = \begin{cases} \frac{Q_3}{L^k} & \text{si la hormiga } k \text{ utiliza el tramo } ij \text{ en su recorrido} \\ 0 & \text{en cualquier otro caso} \end{cases}$$

En estas tres expresiones  $Q_i$  es una constante denominada *intensidad de la feromona*,  $d_{ij}$  es la distancia entre dos ciudades medida de forma euclídea y  $L^k$  es la distancia total recorrida por la hormiga  $k$ .

Definiendo la visibilidad  $\mu_{ij}$  como el inverso de la distancia euclídea entre las ciudades  $i$  y  $j$ , la probabilidad de que una hormiga  $k$  vaya desde la ciudad  $i$  a la ciudad  $j$  en una iteración es una función de la intensidad expresada mediante:

$$p_{ij} = \frac{[\tau_{ij}(t)]^\alpha \cdot [\mu_{ij}(t)]^\beta}{\sum_{j=1}^n [\tau_{ij}(t)]^\alpha \cdot [\mu_{ij}(t)]^\beta}$$

en la que  $\alpha$  y  $\beta$  ponderan la importancia de cada factor. Se evita que una hormiga visite más de una vez una misma ciudad en un recorrido mediante una lista tabú simple (ver 3.3.2).

En definitiva, en cada iteración cada hormiga parte de la ciudad a la que fue asignada y realiza movimientos entre ciudades, basándose en las intensidades de los caminos entre ellas para escoger el más adecuado hasta completar todo el recorrido (hasta que la lista tabú

esté completa). Se memoriza el recorrido de menos coste, se actualizan las intensidades y se vuelve a repetir el proceso.

### 3.5.1 Aplicación de los algoritmos de hormigas a la distribución en planta

Estudios y aplicaciones de algoritmos de búsqueda tabú en la resolución del problema de la distribución en planta puede encontrarse en [Maniezzo et al., 94; Taillard et al., 97; Maniezzo, 99; Gambardella et al., 99; Maniezzo et al., 99; Talbi et al., 01; Solimanpur et al., 05]

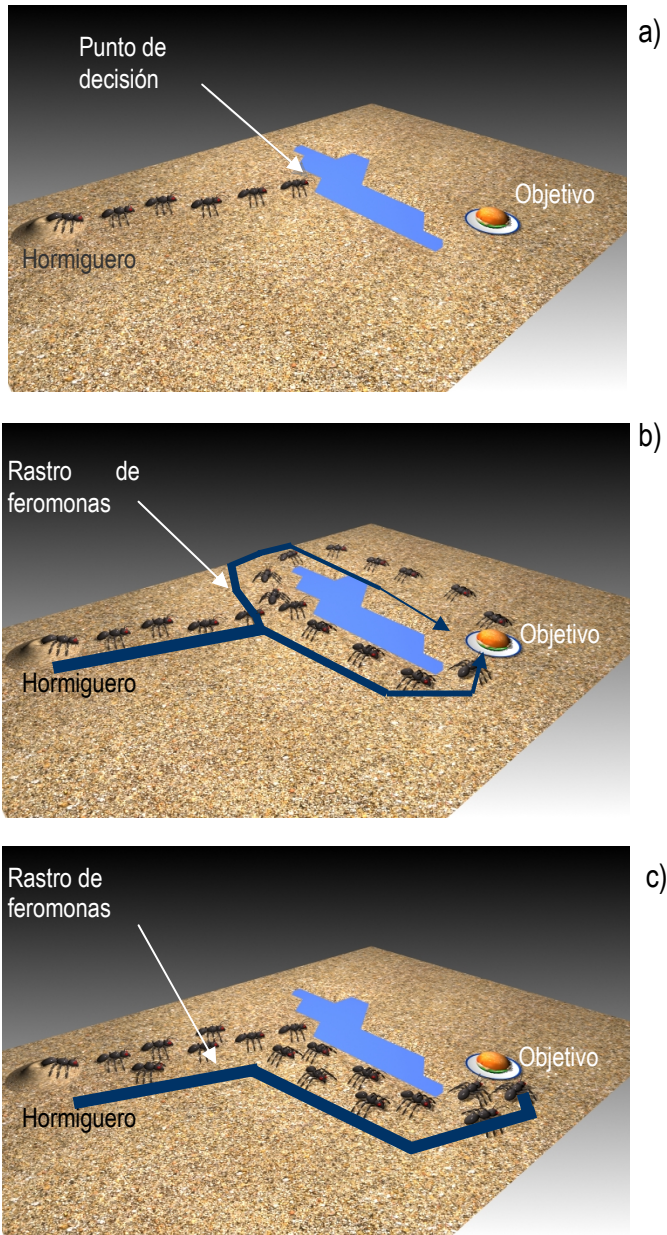


Figura 3.15: a) Las hormigas en su búsqueda de alimento topan con un obstáculo. b) De manera aleatoria las hormigas deciden el camino a seguir; en su camino dejan un rastro de feromonas. c) las hormigas siguen el camino más corto debido al rastro de feromonas más intenso. Adaptado de [Dorigo et al., 97].

### **3.6. Redes neuronales artificiales**

#### **3.6.1 Las redes neuronales naturales**

El cerebro humano es un procesador de información muy eficaz. Este órgano posee unas capacidades deseables para cualquier tipo de sistema de procesamiento artificial [Schmidt, 94]:

- Robustez y tolerancia a fallos: la muerte diaria de miles de neuronas no afecta a su capacidad de proceso.
- Flexibilidad: se adapta a nuevos entornos y circunstancias mediante un proceso de aprendizaje.
- Capacidad para tratar información difusa: extrae información apropiada eliminando ruido e inconsistencias.
- Capacidad para afrontar con éxito situaciones no experimentadas previamente a partir del conocimiento previo de situaciones parecidas.
- Paralelismo.
- Eficiencia energética y pequeño tamaño.

Estas características dotan al cerebro humano de una gran capacidad para procesar y asimilar la información del entorno que le llega a través de los sentidos, a pesar de la imprecisión de la misma. Pero la capacidad más asombrosa del cerebro como máquina de cómputo es su facultad de adaptación y aprendizaje. El cerebro es capaz de aprender nuevas formas de procesar e interpretar la información para adaptarse al entorno sin necesidad de instrucciones previas. Asimismo es capaz de inferir, generalizar y conceptualizar.

##### **3.6.1.1 Funcionamiento de una neurona biológica**

Los primeros y más importantes trabajos sobre neurología fueron realizados por Santiago Ramon y Cajal (1852-1934) y Charles Scott Sherrington (1852-1957). A partir de sus estudios se conoce que el elemento básico que conforma el sistema nervioso son las neuronas. El cerebro humano posee aproximadamente  $10^{11}$  neuronas profundamente interconectadas entre sí. Cada neurona posee unas  $10^4$  conexiones con otras células neuronales. Cada neurona es capaz de recibir, procesar de manera elemental y transmitir pequeños impulsos eléctricos, por lo que se puede establecer una analogía entre una red neuronal y una red de pequeños procesadores.

La morfología de una neurona individual se representa de manera simplificada en la Figura 3.16. Pueden distinguirse tres partes fundamentales: el soma o cuerpo de la célula, las dendritas y el cilindro-eje o axón.

Las dendritas son fibras encargadas de recibir las señales eléctricas procedentes de



otras neuronas o tejidos orgánicos y transmitir las al soma. Las múltiples señales procedentes de las dendritas son procesadas por el soma y transmitidas al axón. El cilindro-eje o axón es una fibra de gran longitud (en relación con el resto de la neurona), conectada al soma por un extremo y que se divide en el otro en una serie de ramificaciones nerviosas. El axón recoge la señal del soma y la transmite a otras neuronas o tejidos orgánicos (como por ejemplo los músculos).




Figura 3.16: Esquema de una neurona.




Figura 3.17: Comunicación entre neuronas. a) Red neuronal. b) Sinapsis.

Las uniones entre neuronas forman estructuras, algunas de las cuales quedan determinadas ya en el nacimiento, y otras que se van generando y modificando durante la vida. La unión se realiza entre una de las ramificaciones del axón de una célula y las dendritas de la siguiente. El punto de contacto de las dos células se denomina sinapsis, y en ella tiene lugar un complejo proceso químico que establece la forma de transmisión de las señales (Figura 3.17).

Las dos membranas de los extremos de las células que se unen en la sinapsis están separados por un espacio de unos 20 nanómetros. A este espacio se la denomina hendidura sináptica. Cuando un potencial de acción llega a la terminación de un axón, las vesículas sinápticas de la neurona presináptica liberan sustancias químicas (neurotransmisores) que atraviesan la membrana celular y pasan a la hendidura sináptica. La dendrita de la neurona postsináptica posee receptores capaces de detectar la presencia de los neurotransmisores en la hendidura. Cuando esto ocurre, la dendrita envía la señal correspondiente al soma de la neurona postsináptica. Este proceso se repite a lo largo de la red neuronal.

Como se ha indicado la estructura de las redes neuronales naturales varía durante la vida. Es precisamente esta variación donde reside su capacidad de adaptación, aprendizaje y memorización. La frecuencia con la que una determinada zona de la red es excitada y la forma en que lo hace, influye en la capacidad de sus sinapsis para transmitir las señales. Un uso frecuente refuerza las conexiones mientras que el desuso puede hacerlas desaparecer. Este modo de funcionamiento fue enunciado por Donald Hebb en 1949 y constituye la denominada regla de Hebb, que influyó decisivamente en el desarrollo de las redes neuronales artificiales [Hebb, 49].

*“When an axon of cell A is near enough to excite a cell B and repeatedly or persistently takes part in firing it, some growth process or metabolic change takes place in one or both cells such that A’s efficiency, as one of the cells firing B, is increased”.*

### 3.6.2 Redes neuronales artificiales

Las redes neuronales artificiales (RNA) pretenden simular los procesos que tienen lugar en las redes neuronales naturales, tratando de lograr sistemas capaces de aprender de la experiencia y de realizar predicciones. Se basan en la densa interconexión de pequeños procesadores o nodos que se denominan “neuronas”.

El desarrollo de las RNA comienza con los estudios de McCulloch y Pitts en la década de los cuarenta con la creación de la primera red neuronal [McCulloch et al., 43]. Uno de los tipos de redes más conocidos, el Perceptron, fue desarrollado por Frank Rosenblatt a final de los 50 [Rosenblatt, 58]. Tras el impulso inicial, las investigaciones sobre el tema se detuvieron repentinamente en 1969, cuando Minsky y Papert demostraron la incapacidad del Perceptron para resolver determinados tipos de problemas (problemas XOR) [Minsky et al., 69]. Los estudios se retomaron posteriormente con la aparición de nuevos tipos de RNA con capacidades para la optimización no lineal.

En [Aleksander et al., 90] se proporciona una definición de Red Neuronal Artificial:

*“Procesador distribuido paralelo que posee una propensión natural para el almacenamiento de conocimiento experimental haciéndolo disponible para su uso. Recuerda al cerebro humano en dos aspectos: el conocimiento se adquiere mediante un proceso de*

aprendizaje, y la conexión entre neuronas (pesos) se utiliza para el almacenamiento del conocimiento.”

### 3.6.2.1 La neurona artificial

Una neurona artificial es una abstracción matemática del funcionamiento de las neuronas naturales. Simplificando mucho podría compararse con un amplificador operacional en el que se reciben las señales de entrada, se comprueba si se supera una función de activación, y si es pertinente se produce la señal de salida. En la Figura 3.18 las




Figura 3.18: Neurona artificial.

entradas  $X_i$  representan las señales de otras neuronas que llegan a las sinapsis correspondientes. Los pesos  $w_i$  representan la intensidad con que la sinapsis transmite la señal de la neurona presináptica a la postsináptica.  $\theta$  es la función de activación de la neurona, que determina el umbral que deben sobrepasar las señales para que se produzca la salida  $J$ .

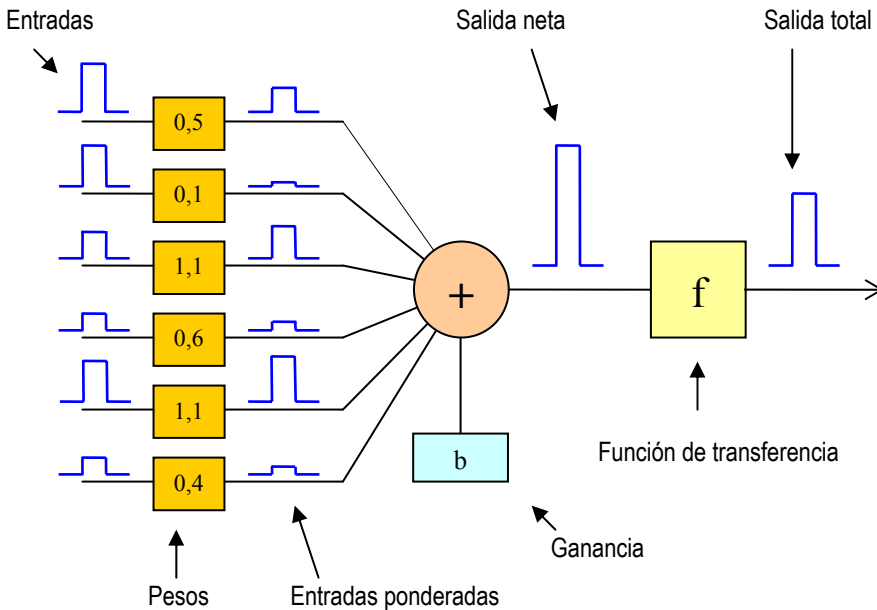


Figura 3.19: Proceso entrada-salida en una neurona artificial. Adaptado de [Acosta-Buitrago et al., 05].

En las neuronas artificiales las entradas pueden tomar valores reales continuos (en contraste con las señales discretas de las neuronas naturales). Los pesos son reales positivos (excitatorios), nulos o negativos (inhibitorios). El nodo neuronal suma el valor de las entradas multiplicadas por los pesos correspondientes, comprueba si se supera el valor umbral y, en su caso, produce la salida a través de una función de transferencia.

El funcionamiento de una neurona artificial se aprecia en la Figura 3.19.

Las señales de entrada son ponderadas multiplicándolas por el peso correspondiente, que corresponderían en la versión natural de la neurona a la fortaleza de la conexión sináptica. Las señales ponderadas llegan al nodo neuronal que actúa como sumatorio de señales. La salida del nodo se denomina salida neta, y se calcula como el sumatorio de las entradas ponderadas más un valor **b** denominado ganancia. La salida neta se emplea como entrada a la función de transferencia proporcionando la salida total o respuesta de la neurona artificial. Esta representación puede simplificarse como se muestra en la Figura 3.20.

La salida neta de la neurona es:

$$n = \sum_{i=1}^r p_i w_i + b$$

siendo la respuesta neuronal a las entradas:

$$a = f(n) = f\left(\sum_{i=1}^r p_i w_i + b\right)$$

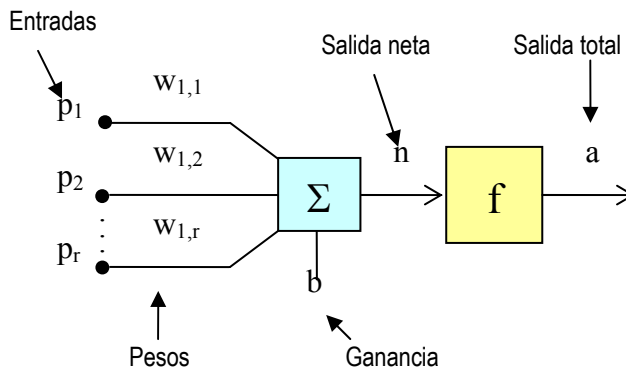



Figura 3.20: Representación simplificada de una neurona artificial.

### 3.6.2.2 Topología de las Redes Neuronales

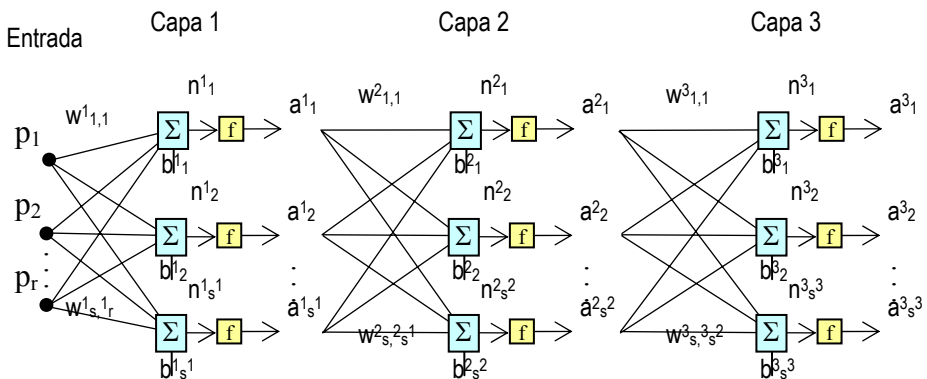
Las RNA suelen estar formadas por varias neuronas interconectadas (salvo excepciones como la red Perceptron formada por una sola). La disposición y forma de conexión varía de unos tipos de redes a otras, pero de forma general las neuronas se disponen en capas.

La **capa de entrada** no es en sí una capa de neuronas sino que son los puntos donde se recogen las señales que se entregarán a la red. En esta capa no se procesa la información. Las **capas ocultas** recogen la información de la capa de entrada y la procesan. El número de capas ocultas, el número de neuronas por capa y la forma en que se conectan varían de unas redes a otras. La **capa de salida** recibe la información de la última capa oculta y la transmite al medio.

En la *Figura 3.21* se expone una red neuronal con una única capa oculta formada por  $s$  neuronas con  $r$  entradas. En el caso de existir más de una capa oculta, las salidas de las neuronas de la primera capa oculta son las entradas de las de la siguiente (*Figura 3.22*).



*Figura 3.21: Red neuronal con una sola capa oculta,  $r$  entradas y  $s$  neuronas. Adaptado de [Acosta-Buitrago et al., 05].*



*Figura 3.22: Red neuronal con tres capas ocultas.*

### 3.6.3 Entrenamiento de una red neuronal

Una vez configurada la topología de la red, y para que esta pueda ofrecer salidas convenientes a las entradas que se le presenten, debe ser sometida a un proceso denominado *entrenamiento*. En función del tipo de red este proceso puede diferir mucho. Como ejemplo se describirá el entrenamiento de la red más simple y extendida, el Perceptron.

El Perceptron es un tipo de red de aprendizaje supervisado, es decir, para poder adaptar su comportamiento al problema planteado se le debe ofrecer el resultado esperado a una serie determinada de entradas. Las salidas ofrecidas por la red a estas entradas son comparadas con las salidas esperadas y se evalúa el error cometido. En función de ese error se modifican los pesos de los enlaces y los valores de las ganancias de las neuronas (una sola en el caso del Perceptron). Este proceso se repite hasta conseguir que el error alcance una cota superior determinada, punto en el cual se considera que la red está entrenada (Figura 3.23).

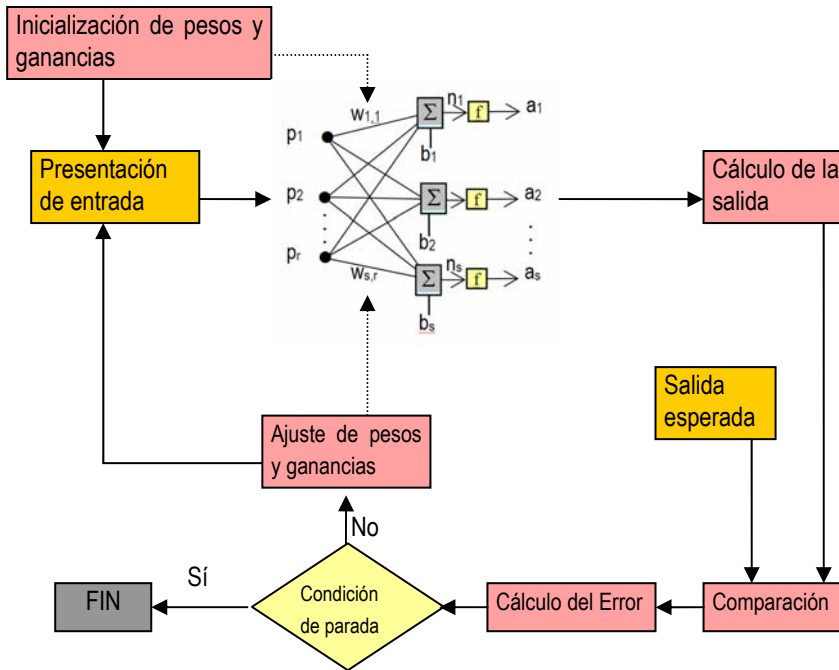


Figura 3.23: Entrenamiento de una red neuronal.

En el caso de la red Perceptron, la modificación de los pesos en cada iteración puede hacerse sumando al vector de pesos el vector de entradas multiplicado por el error ( $\epsilon_i$ ) obtenido para dicha entrada.

$$w_{i+1} = w_i + \epsilon_i p_i = W_i + (t_i - a_i) p_i$$

donde  $t_i$  es la salida esperada para la entrada  $p_i$ . En el caso de las ganancias la expresión empleada habitualmente es:

$$b_i = b_{i+1} + \varepsilon$$

### 3.6.4 Tipos de redes neuronales

Existen múltiples posibles clasificaciones de las RNA atendiendo a criterios como la forma de aprendizaje, el tipo de valores de entrada, el tipo de funciones de activación, su topología. Una posible clasificación es la que se ofrece en [Acosta-Buitrago et al., 05]:

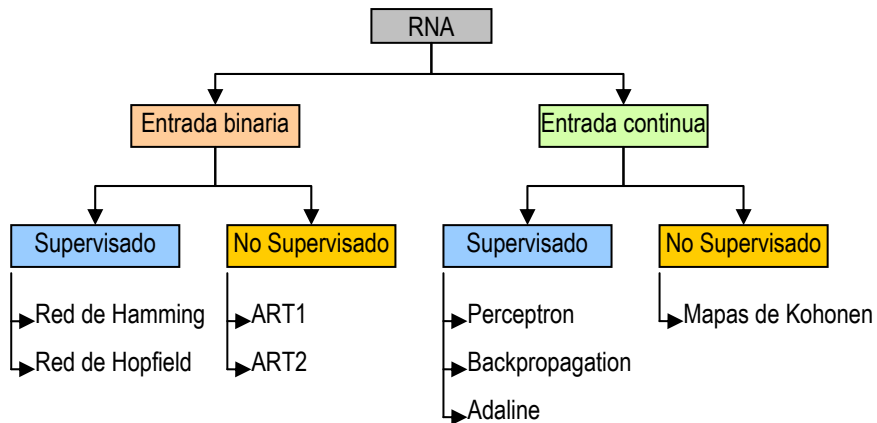


Figura 3.24: Posible clasificación de las redes neuronales. Tomado de [Acosta-Buitrago et al., 05]

La clasificación presentada emplea como primer criterio el tipo de entrada que se presenta a la red y, posteriormente, si el aprendizaje es supervisado o no, es decir, si es necesario o no conocer las salidas convenientes a las entradas empleadas durante el entrenamiento de la red. A parte de las presentadas en el gráfico existen otros tipos de redes menos extendidas.

#### 3.6.4.1 El Perceptron

El Perceptron fue desarrollado por Frank Rosenblatt en 1957. Posee una única neurona que realiza la suma ponderada de las entradas, le resta un valor umbral y pasa el resultado a una función de transferencia de tipo escalón. El aprendizaje de la red es de tipo supervisado. Su empleo está limitado a problemas linealmente separables cuyas salidas puedan clasificarse en dos categorías diferenciadas. La función XOR es un caso de problema que una red Perceptron no puede resolver tal y como demostraron [Minsky et al., 69].

Una variante de esta red es el Perceptron Multicapa. En ella existe un número variable de neuronas que se distribuyen en varias capas. Esta red solventa la limitación del Perceptron mono-neurona siendo capaz de resolver problemas no linealmente separables. Se emplea con frecuencia en el reconocimiento de patrones.

### 3.6.4.2 Adaline

Adaline es un acrónimo de “Adaptative linear element”. Este tipo de red se diferencia del Perceptron únicamente en la función de transferencia empleada. Mientras que en el Perceptron es una función escalon, en Adaline es una función lineal. De nuevo está limitada la resolución de problemas linealmente separables, pero dado que es capaz de minimizar el error medio cuadrático entrada-salida, es muy empleada en el procesamiento de señales digitales.

### 3.6.4.3 Backpropagation

Éste es un tipo de red de aprendizaje supervisado con múltiples capas internas. El nombre (Backpropagation) se debe al sistema empleado para entrenar a la red. Las entradas empleadas dan lugar a salidas que son comparadas con las salidas esperadas. De esta forma se calcula una señal de error que se propaga por la red en dirección inversa, desde la salida hacia la entrada. Cada una de las neuronas de las capas ocultas recibe una señal de error que es una fracción del error total, y que dependerá de cuánto ha contribuido individualmente a la generación de la salida. Esta señal se propaga capa por capa hasta la entrada. Basándose en la señal de error que recibe, cada neurona adapta sus pesos de conexión para hacer converger, tras el número suficiente de iteraciones, las salidas producidas a las esperadas. Ésta puede considerarse la red multicapa más potente, sencilla y flexible. Es capaz de aproximar cualquier función y su empleo abarca los ámbitos más diversos.

### 3.6.4.4 Red de Hopfield

Este tipo de redes surgió para el estudio de sistemas gobernados por ecuaciones diferenciales no lineales, y es muy empleado en la resolución de problemas de optimización combinatoria con restricciones, expresables mediante funciones objetivo cuadráticas y con coeficientes simétricos [Hopfield et al., 85]. Su capacidad para afrontar problemas dinámicos no lineales se debe a que emplea información de las salidas anteriores para generar la salida actual. Por este motivo a este tipo de redes se les denomina *recurrentes*.

Las redes de Hopfield son monocapa no supervisadas, no necesitan ser entrenadas sino que es la propia dinámica de la red la que ofrece una solución al problema.

### 3.6.4.5 Otros tipos de redes

Aparte de las ya mencionadas existe un gran número de redes con características y usos particulares. Las *redes de Kohonen*, también llamadas mapas de Kohonen, tienen la capacidad de formar mapas de características de manera similar a como ocurre en el cerebro con la información captada a través de los sentidos. Las redes *Instar* y *Outstar* resuelven el problema de reconocimiento de patrones. La red de *Hamming*, entrenada por competición entre las neuronas de la capa de salida, permite escoger el patrón prototipo más adecuado a las entradas de la red.

Las redes *Art1* y *Art2*, los mapas auto-organizativos *SOM*, o las redes de *Elman* son una muestra más de la gran diversidad de redes desarrollada.



### 3.6.5 Aplicación de las redes neuronales al problema de la distribución en planta

Es posible encontrar en la bibliografía diversas formas de aplicar las redes neuronales al problema cuadrático de asignación: [Bousonocalzon et al., 95; Obuchi et al., 96; Tsuchiya et al., 96; Ishii et al., 98; Rossin et al., 99]. Se emplean tipos de redes diferentes, predominando las Hopfield, y en algunos casos su uso se combina con alguna metaheurística, por ejemplo la búsqueda tabú [Talbi et al., 98; Hasegawa et al., 02], dando lugar a técnicas híbridas.

Como ejemplo de aplicación se describe a continuación la técnica empleada por Tsuchiya [Tsuchiya et al., 96]. Este autor propone una red formada por una matriz de  $n \times n$  neuronas, siendo  $n$  la dimensión del QAP a resolver. Se trata de una red sin entrenamiento con salida binaria competitiva y recurrente. Si la salida de la neurona  $(i,j)$  es 1, la actividad  $i$  será asignada a la posición  $j$ . Si la salida es cero la actividad  $i$  no se asignará a  $j$ . Es evidente que las neuronas de una misma fila o columna son excluyentes. Si se activa una neurona de la fila  $i$ , ninguna otra neurona de esta fila podrá activarse, puesto que esto implicaría que una actividad se asignaría a dos ubicaciones.

La función que determina las neuronas que se activarán depende de las entradas  $I_{ij}$  que llegan a cada neurona. Inicialmente se activa la neurona que posea la entrada máxima, quedando vedadas para próximas activaciones la fila y columna a la que pertenece esa neurona. La siguiente neurona a activar será aquella que posea la entrada máxima, sin contar con las de las neuronas ya activadas, y que como se ha dicho, no esté situada en una posición vedada. Este proceso se repite hasta que no queden posiciones de la matriz sin vedar, es decir  $n$  veces. Así pues la salida de  $n$  neuronas será 1 y la de las  $n^2-1$  neuronas restantes será 0. Esta salida define la ubicación asignada a cada una de las actividades.

Las nuevas entradas al sistema dependerán de la validez de la salida obtenida. De forma general la variación de la entrada a la neurona  $ij$  toma el valor:

$$\frac{dI_{ij}}{dt} = \frac{\partial E(O_{11}, \dots, O_{ij}, \dots, O_{NN})}{\partial O_{ij}}$$

es decir, la variación de la entrada  $ij$  dependerá de la variación de la magnitud empleada para evaluar la solución ( $E$ ), al modificar la salida de la neurona  $ij$ . Se trata de minimizar el valor de  $E$  siguiendo el gradiente descendiente de dicha función.

La función empleada en [Tsuchiya et al., 96] es la función de coste de la distribución obtenida. La formulación empleada es:

$$\frac{dI_{ij}}{dt} = Q - R$$

donde  $Q$  es el coste objetivo que se pretende alcanzar (es habitual dar a  $Q$  el valor 0), y  $R$  el coste real calculado de la distribución en la que la actividad  $i$  ha sido asignada a la ubicación  $j$ . Dado que  $Q$  será siempre menor o igual que  $R$ , las variaciones de las entradas serán siempre negativas o nulas. De esta forma se penaliza a las neuronas cuya activación suponga un gran aumento del coste, haciendo disminuir el valor de la entrada a dicha

neurona.

En [Takefuji, 92] se propone calcular la variación de las entradas a la red mediante la expresión:

$$\frac{dl_{ij}}{dt} = \begin{cases} (Q - R)O_{ij} & \text{si } (t \bmod 10) < \omega \\ Q - R & \text{en\_otro\_caso} \end{cases}$$

donde  $t$  representa el número de iteraciones y  $\omega$  un entero constante. Mediante esta forma de cálculo se consigue aumentar la velocidad de convergencia y proporciona la posibilidad de escapar de óptimos locales, dado que cuando se cumple la primera de las condiciones de la ecuación, una neurona activada puede ser penalizada.

# 4

**Algoritmos genéticos: funcionamiento y  
bases teóricas**

## 4. ALGORITMOS GENÉTICOS: FUNCIONAMIENTO Y BASES TEÓRICAS.

### 4.1. Introducción

Aunque los algoritmos genéticos fueron tratados brevemente en el capítulo anterior, incluyéndolos en el grupo de técnicas de computación evolutiva, se considera necesario en este punto, dado que será la técnica empleada en la metodología que la presente tesis propone, realizar una exposición más completa y detallada de su estructura, sus principios de funcionamiento, las bases teóricas que los sustentan, sus diferentes variantes, su ámbito de uso y aplicaciones, así como de las limitaciones prácticas y las estrategias para superarlas. Tras este estudio en profundidad, será en el capítulo siguiente donde se aborde la aplicación de los algoritmos al caso concreto de la distribución en planta.

El aumento de la capacidad de proceso de los ordenadores durante la década de los 60, convirtieron a éstos en instrumentos adecuados para la resolución de problemas con grandes requerimientos de cálculo. A finales de esa década y principios de la siguiente, un grupo de investigadores de la Universidad de Michigan en Ann Arbor, denominado *Logic of Computers*, encabezados por John Holland, desarrollan los algoritmos genéticos basándose en una analogía con la evolución de los seres vivos [Holland, 75].

La resolución de un problema complejo determinado puede asimilarse a la búsqueda de una solución óptima (o al menos sub-óptima) en un espacio de soluciones extenso. La naturaleza se enfrenta a un problema de este estilo en su búsqueda de la mejor adaptación de los individuos al medio. Los miembros de una determinada población compiten entre ellos en la búsqueda de la supervivencia.




Figura 4.1: Estructura celular.

Aquellos individuos capaces de adaptarse mejor a las condiciones del medio que los rodea tendrán mayor probabilidad de sobrevivir. Los miembros de la población con mayor habilidad para conseguir alimentos, soportar las condiciones climáticas o defenderse de otras especies, disfrutarán de una esperanza de vida mayor, de una mayor probabilidad de reproducirse y lograrán una descendencia más numerosa. De esta manera, las características del individuo que han determinado su mayor habilidad para desenvolverse en el medio serán transmitidas a su descendencia. Por otra parte, los individuos menos dotados y adaptados al entorno tendrán una probabilidad menor de transmitir dichas características a las siguientes generaciones.

El conjunto de rasgos o características observables del individuo (fenotipo) que han determinado su éxito o su fracaso, son la expresión de la información contenida en su carga

genética<sup>22</sup>. Dicha información se encuentra codificada en los genes, una secuencia de nucleótidos (fragmento de ADN) en una determinada localización de un cromosoma específico. Los cromosomas, generalmente agrupados por parejas, se encuentran en el interior del núcleo celular (Figura 4.1).

Durante la reproducción cada uno de los padres transmite a su descendencia parte de su carga genética. Como resultado de este cruce los individuos descendientes poseerán características fenéticas de ambos progenitores. Dado que los individuos mejor dotados poseerán una mayor descendencia, las sucesivas generaciones disfrutarán de la combinación de las buenas características de generaciones pasadas, lo que se traducirá en una mejor adaptación al medio.

El hecho de que la probabilidad de reproducción sea mayor en los individuos mejor dotados, no significa que por diversas razones individuos con una menor capacidad de adaptación al medio, sean capaces de sobrevivir y de transmitir su carga genética a generaciones futuras. Aunque las características de dichos individuos no sean las apropiadas para la supervivencia en unas condiciones determinadas, el cruce de su información genética con la de otros miembros de la población, puede dar lugar a particularidades que resulten exitosas en generaciones futuras. Esto introduce diversidad genética en el proceso y una mayor capacidad de respuesta ante cambios en el entorno.

Otra fuente de variabilidad genética es la debida a las mutaciones producidas en el material genético. Estas mutaciones introducen en la población características diferentes a las heredadas de generaciones anteriores. En realidad, este cambio aleatorio en los genes de un organismo, difícilmente procurará una mejora en un individuo bien adaptado a su entorno; la mayor parte de las características que aportan las mutaciones suelen desaparecer durante el proceso de selección. Sin embargo, en casos determinados, pueden suponer rasgos que permitan una mayor adaptación de los individuos al medio.

La información genética determina el poder de adaptación de cada especie (y dentro de cada especie, de cada individuo). Los individuos más adaptados sobreviven y se reproducen en mayor medida dando lugar al proceso de cambio dirigido denominado Selección Natural. Dicho proceso resulta evidentemente eficaz y, sobre todo, robusto, dado que permite la adaptación exitosa de las poblaciones en ambientes mutables e inciertos. En realidad, la Selección Natural no persigue una mejora continua de los individuos y las poblaciones, si no la mejor adaptación posible de estos al entorno en el que sobreviven. Individuos bien adaptados a un entorno concreto, pueden tener un peor comportamiento en los entornos de sus antecesores. La selección natural, y por analogía en los algoritmos genéticos, son procesos robustos dado que permiten la obtención de buenas soluciones en entornos muy diferentes.

---

<sup>22</sup> Siendo exhaustivos, el fenotipo no es consecuencia únicamente de la información genética del individuo, sino que se ve afectado por las condiciones ambientales en las que el individuo se desarrolla. Así, el glosario de términos genéticos del National Human Genome Research Institute define fenotipo como: "[...]conjunto de rasgos o características observables de un organismo. [...] el fenotipo es siempre algo que podemos observar. Se puede observar en la clínica, en el laboratorio o en las interacciones sociales. El fenotipo no es la constitución genética de un organismo. Es de algún modo la expresión o el resultado de la constitución genética de ese organismo y está determinado por los genes y por el ambiente en que el individuo crece y se desarrolla."

## 4.2. Terminología y analogías planteadas

Antes de profundizar en la exposición se hace necesario proporcionar algunas definiciones de términos posteriormente empleados:

**Solución o alternativa:** Configuración compatible con las restricciones del problema y que le da solución.

**Individuo:** Equivalente analógicamente a solución o alternativa.

**Espacio de soluciones:** Conjunto de todas las posibles soluciones a un problema determinado que es posible alcanzar con el sistema de resolución empleado. Equivale a espacio de individuos.

**Población:** Conjunto de individuos existentes en un momento (iteración) dado. En adelante denotado por **P**.

**Generación:** Proceso de creación de nuevos individuos. También se emplea como sinónimo de población.

**Función objetivo o función de evaluación:** Función empleada para evaluar la calidad de las soluciones. Analógicamente mediría la adaptación de los individuos a su entorno, denominándose entonces *adaptabilidad*. Generalmente es una función definida sobre el espacio de soluciones **S** y con imagen en **R**:

$$FO: S \rightarrow R$$

Los problemas planteados pretenden encontrar individuos en **S** que minimicen (o en su caso maximicen) su imagen en **R**.

**Solución óptima:** Solución  $s \in S$  tal que **FO(s)** sea óptimo. Analógicamente, el individuo mejor adaptado a su entorno.

**Solución sub-óptima:** Solución de calidad cercana a la de la solución óptima o bien, de calidad aceptable para las condiciones del problema planteado.

**Cadena, estructura o codificación:** Secuencia de elementos que representa (codifica) a una solución o individuo. En la analogía natural es un *cromosoma*.

**Gen:** Analogía natural de cada uno de los elementos que conforman la cadena o cromosoma que representa un individuo.

**Alelo:** Valor que puede adoptar un gen.

**Genotipo:** Se empleará para denotar el contenido genético de un individuo, es decir, el cromosoma que lo codifica.

**Medio externo:** Entorno en el que se desarrollan y compiten los individuos. En el caso del presente trabajo será análogo al dominio de ubicación de las actividades.

**Fenotipo:** Características físicas de un individuo determinadas por su genotipo y las condiciones del medio externo.

Las figuras siguientes, adaptadas de [Santamarina, 95], aclaran algunas de las analogías planteadas en el caso del problema de distribución en planta. La Figura 4.2 representa la

analogía entre una solución al problema y su codificación, y un individuo y su genotipo.




Figura 4.2: Analogías en los algoritmos genéticos. Adaptado de [Santamarina, 95].

La relación entre la codificación de una solución y la propia solución estará influida por el dominio de ubicación de las actividades, de la misma forma que el fenotipo de un individuo depende de su genotipo y, además, del medio en el que se desenvuelve (Figura 4.4). Dado un medio externo concreto, diferentes genotipos darán lugar a individuos diferentes. De la misma forma, dado un dominio de ubicación fijo, diferentes codificaciones darán lugar a diferentes soluciones (Figura 4.4).

En la Figura 4.5 puede apreciarse qué ocurre en el caso de que una misma codificación se exponga a diferentes dominios. Como se mostrará más adelante, una de las condiciones para implementar correctamente un algoritmo genético es que exista una correspondencia biunívoca entre el espacio de soluciones y el espacio de las codificaciones. Esto es; cada codificación representa una y sólo una solución, y toda solución puede ser codificada y sólo de una manera.

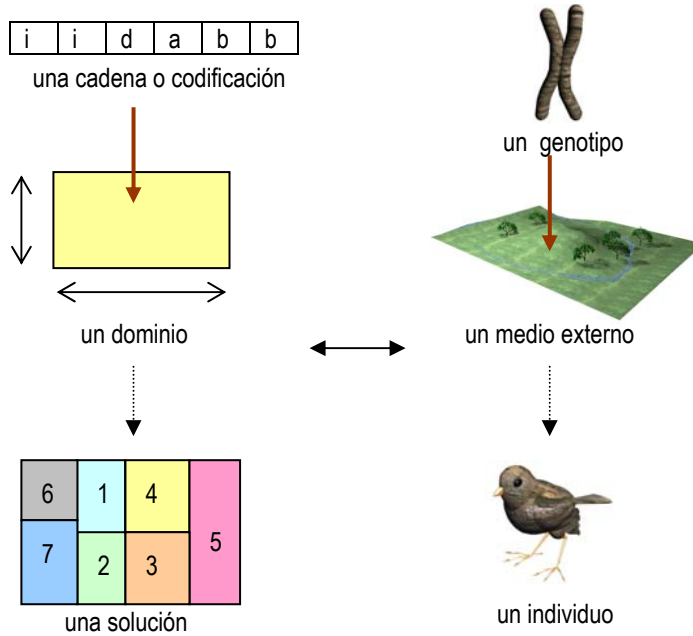


Figura 4.4: Analogías en los algoritmos genéticos (II). Adaptado de [Santamarina, 95].

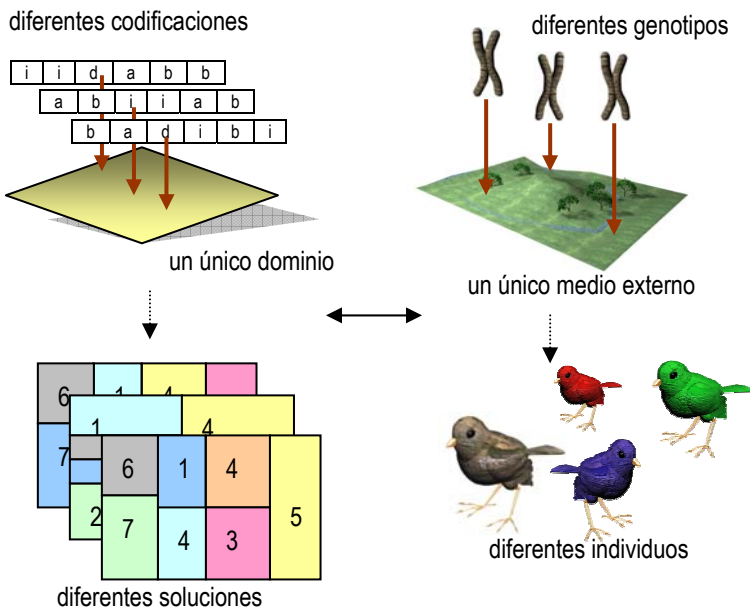


Figura 4.4: Analogías en los algoritmos genéticos (III). Adaptado de [Santamarina, 95].



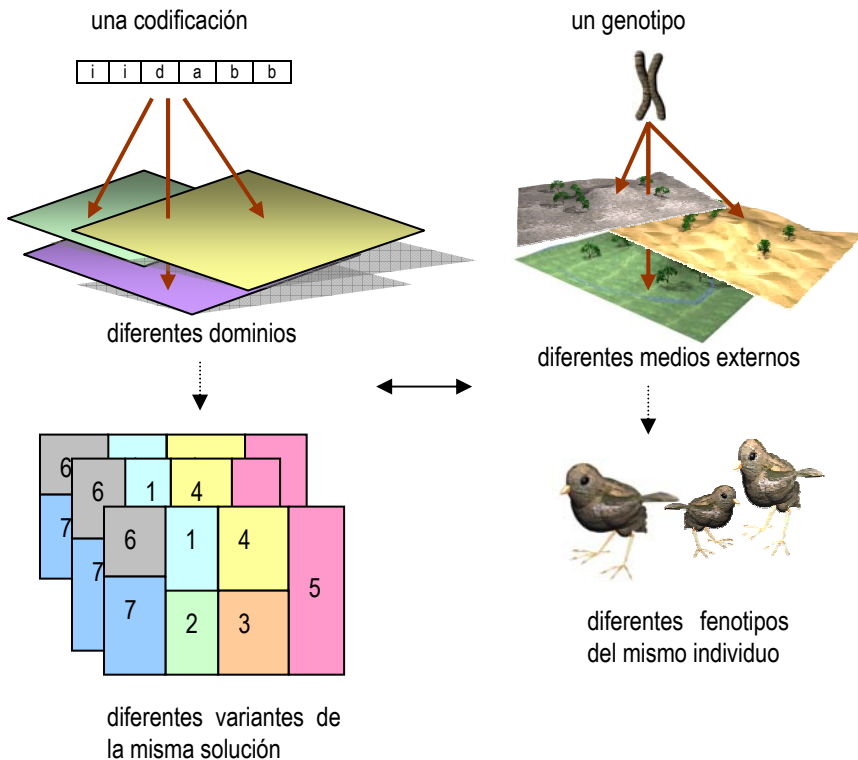


Figura 4.5: Analogías en los algoritmos genéticos (IV). Adaptado de [Santamarina, 95].

Observando la Figura 4.5 podría pensarse que una determinada cadena da lugar a individuos diferentes en función del entorno a la que se expone, con lo que se incumpliría la condición anterior. Sin embargo, lo que ocurre en realidad es que un determinado genotipo expuesto a diferentes medios, produce diferentes expresiones físicas del mismo individuo, es decir, diferentes fenotipos de un mismo individuo.

### 4.3. Estructura básica de un algoritmo genético

En el capítulo anterior ya se expuso brevemente la estructura básica de un algoritmo genético, pero se considera conveniente reproducirla aquí, para que sirva de guía al análisis detallado de cada uno de sus componentes.

El algoritmo comienza creando un número determinado de cadenas que codifican un conjunto de soluciones al problema objeto de estudio. Este conjunto de individuos representa la población inicial y su tamaño es un parámetro fundamental del proceso.

El criterio para valorar la calidad de cada una de las soluciones (en la analogía el grado de adecuación de cada individuo al entorno) es el valor de la función objetivo. Así en un

proceso denominado genéricamente *evaluación*, se determina el valor de la función para cada individuo.

Una vez conocida la valoración de cada individuo se somete a la población a un proceso denominado *selección*, mediante el cuál se escoge un grupo de individuos que determinarán la nueva generación. La selección puede llevarse a cabo mediante diversos procedimientos, pero en general se realiza otorgando una mayor probabilidad de ser escogido a los individuos mejor valorados.

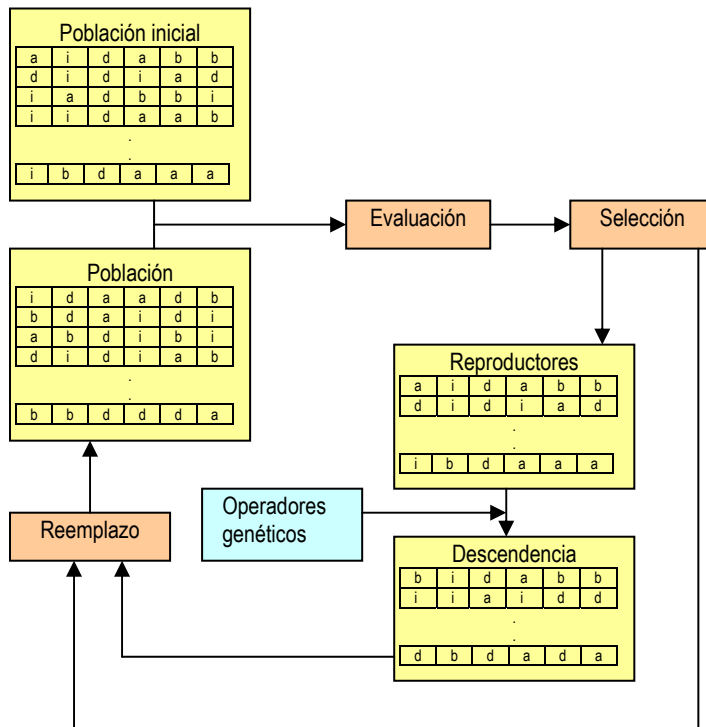


Figura 4.6: Esquema general de un algoritmo genético.

Aunque de esta fase del algoritmo existen múltiples variantes, en general, los individuos escogidos forman una población intermedia o auxiliar, de la que se seleccionarán los individuos que se reproducirán de manera efectiva. Estos serán sometidos a los operadores genéticos (habitualmente cruzamiento y mutación), que permitirán obtener una descendencia que recoja las mejores características de los progenitores e introduzcan diversidad en la población. Del conjunto de la población auxiliar y de la descendencia se escogerá el número suficiente de individuos como para formar una nueva población. Este proceso de sustitución de los individuos de la generación anterior por nuevos individuos (que pueden ser idénticos a los ya existentes) se denomina *reemplazo*. Todo el proceso (evaluación, selección, aplicación de operadores y reemplazo) se repite hasta que se cumple un criterio de parada preestablecido.

Este procedimiento general posee algunas variantes. En algunos casos existe un doble

proceso de selección. En una primera fase se seleccionan de la población los individuos destinados a reproducirse, y en la segunda se seleccionan, de manera independiente, aquellos que pasarán directamente a la nueva población. En otros casos se selecciona directamente de la población un grupo pequeño de individuos que se reproducirán y sustituirán a sus progenitores o a otros miembros de la población. Además, existen diferentes propuestas en cuanto a la forma de muestrear la población, la forma de seleccionar a los individuos, la forma de aplicar los operadores genéticos, el criterio de parada, la forma de construir la función objetivo...

Ante toda esta diversidad se hace necesario establecer las condiciones para una correcta implementación de los algoritmos genéticos.

#### **4.3.1 Condiciones para una correcta implementación de los algoritmos genéticos**

Para implementar de forma adecuada y con garantías un algoritmo genético es necesario observar el cumplimiento de una serie de condiciones, que pueden resumirse en la correcta definición de los siguientes aspectos:

- Codificación de las soluciones
- Creación de la población inicial
- Función de evaluación
- Criterios de selección
- Operadores genéticos
- Tratamiento de los individuos no factibles
- Parámetros de funcionamiento
- Criterio de parada

Cada uno de estos aspectos y la forma de una adecuada implementación serán tratados en profundidad posteriormente, pero antes, es necesario exponer algunos resultados teóricos.

### **4.4. Base teórica de los algoritmos genéticos**

El algoritmo genético es con mucha probabilidad la metaheurística con más base teórica de las expuestas en este trabajo. Estos resultados teóricos permiten conocer por qué y cómo funcionan los algoritmos, y establecer las condiciones que maximizarán su eficacia.

#### **4.4.1 Concepto de esquema**

Como ya se ha expuesto, en los algoritmos genéticos los individuos deben ser codificados mediante cadenas (**s**) de longitud finita (**k**). A cada uno de los componentes de

esa cadena se le denomina *gen*, y puede adoptar valores de un conjunto predefinido  $\{\Theta\}$ . Cada uno de los valores de dicho conjunto se denomina *alelo*. Así pues, llamando **S** al espacio de todas las cadenas se cumple que:

$$\forall \mathbf{s} \in \mathbf{S}; \mathbf{s}=(s_1, \dots, s_i, \dots, s_k) / \forall s_i, s_i \in \{\Theta\}$$

El tamaño del espacio de las cadenas será:

$$|\mathbf{S}| = |\Theta|^k$$

Es decir, el número de cadenas posibles es igual al número de alelos elevado a la longitud de las cadenas. Mediante la introducción del concepto de esquema, es posible analizar cómo un algoritmo genético analiza el espacio de las cadenas o estructuras que representan las soluciones.

Un esquema podría definirse como un patrón de similitud entre un grupo de cadenas. Este patrón puede representar a todas las cadenas que se adaptan al patrón. Definiéndolo en sentido estricto se dirá que un esquema (**H**) es una cadena en la que sus componentes se definen sobre el conjunto  $\{\Theta \cap \#\}$  siendo # un símbolo que representa cualquiera de los alelos de  $\Theta$ . Así pues el tamaño del espacio de los esquemas es:

$$(|\Theta|+1)^k$$

Como ejemplo, el esquema de carácter binario (0,#,#,1,1,0), es representativo de las cadenas (0,0,0,1,1,0), (0,0,1,1,1,0), (0,1,0,1,1,0) y (0,1,1,1,1,0).

A partir de lo expuesto puede deducirse que para un espacio de cadenas de longitud **k**, cuyos elementos pueden tomar **a** valores diferentes:

- un esquema **H** que contenga **n** símbolos # representa a **a<sup>n</sup>** cadenas
- una cadena dada puede ser representada por **2<sup>k</sup>** esquemas distintos
- en una población de **P** cadenas existen entre **a<sup>k</sup>** y **P · a<sup>k</sup>** esquemas distintos

Dos caracterizadores fundamentales de un esquema son el orden y la longitud. Se denomina **orden de un esquema o(H)** al número de componentes de la cadena diferentes de #, es decir, fijados. Se denomina **longitud de un esquema δ(H)**, a la diferencia entre las posiciones ocupadas por el primer y el último componente fijo (distintos de #).

Como ejemplo, el esquema (0,#,#,1,1,0) es de orden 4 y de longitud 5.

Dado que ya es conocido que un esquema **H** que contenga **n** símbolos # representa a **a<sup>n</sup>** cadenas, es fácil deducir que el número de cadenas representadas se puede calcular también como **a<sup>k-o(H)</sup>**, es decir, cuanto mayor sea el orden del esquema a menos cadenas representará. El orden de un esquema será posteriormente empleado para deducir la probabilidad de supervivencia de un esquema frente al operador mutación. La longitud del esquema es una medida de la compacidad de la representación, y se empleará para estimar la probabilidad de supervivencia del esquema frente a los cruces.

Analizando la evolución de los esquemas durante la ejecución de los algoritmos genéticos, John H. Holland dedujo dos resultados teóricos conocidos como el teorema fundamental de los algoritmos genéticos y el paralelismo implícito de los algoritmos genéticos. Ambos resultados son abordados a continuación.

#### 4.4.2 Teorema fundamental de los algoritmos genéticos. Teorema del esquema o teorema de Holland

Considérese una población de tamaño  $p$  de cadenas de longitud  $k$  en una generación  $g$ . Llámese  $m(H,g)$  al número de cadenas de la población que se ajustan a un esquema  $H$ . El teorema de Holland, permite realizar una estimación del número de cadenas ajustadas a  $H$  que existirán en la siguiente generación de un *algoritmo genético básico*<sup>23</sup>, tras haber actuado los operadores genéticos básicos (selección, cruzamiento y mutación).

De forma simplificada puede expresarse que:

$$m(H,g+1) = m(H,g) k_g k_s$$

Es decir, el número de cadenas representadas por el esquema  $H$  en una generación, será el de la generación anterior afectado por dos factores, el factor de crecimiento ( $k_g$ ) y el factor de supervivencia ( $k_s$ ). El factor de crecimiento mide la tendencia del esquema a aumentar su presencia en la población, estando relacionado con el operador selección. El factor de supervivencia mide la probabilidad de que el esquema sobreviva en la generación siguiente, estando relacionado con los operadores cruce y mutación.

El operador selección escoge a los individuos que se reproducirán en función su adaptación. En un algoritmo genético básico la selección se realiza por sorteo, por lo que:

$$P(s,g) = \frac{\mu(s)}{\bar{\mu}}$$

donde:

- $P(s,g)$  es la probabilidad de que la cadena  $s$  sea seleccionada con fines reproductivos en la generación  $g$ .
- $\mu(s)$  es la adaptación de la cadena  $s$  en la generación  $g$ .
- $\bar{\mu}$  es la adaptación media de todas las cadenas presentes en la población en la generación  $g$ .

De la misma manera, el número de cadenas representadas por un determinado esquema  $H$  que serán escogidas para la reproducción puede expresarse como:

$$m(H,g)_s = m(H,g) \frac{\mu(H)}{\bar{\mu}}$$

donde:

---

<sup>23</sup> El teorema fundamental se enuncia sobre un algoritmo genético propuesto por Goldberg [Goldberg, 89a], habitualmente denominado algoritmo genético básico (SGA). En un SGA la codificación de los individuos es binaria, la inicialización aleatoria, la selección por sorteo y el reemplazo inmediato. Los operadores genéticos son el cruzamiento y la mutación bit a bit. De manera ideal, se considera a los operadores cerrados (no pueden generar individuos no factibles) por lo que no existe tratamiento de individuos no válidos.

- $m(\mathbf{H},g)$  es el número de cadenas representadas por un determinado esquema  $\mathbf{H}$  que serán escogidas para la reproducción en la generación  $g$ .
- $m(\mathbf{H},g)$  es el número de cadenas representadas por un determinado esquema  $\mathbf{H}$  que presentes en la población en la generación  $g$ .
- $\mu(\mathbf{H})$  es la adaptación media de las cadenas representadas por  $\mathbf{H}$  en la generación  $g$ .
- $\bar{\mu}$  es la adaptación media de todas las cadenas presentes en la población en la generación  $g$ .

Así pues, el factor de crecimiento ( $k_g$ ) se expresa como:

$$k_g = \frac{\mu(\mathbf{H})}{\bar{\mu}}$$

Aunque un esquema sea seleccionado como reproductor, la aplicación de los operadores genéticos puede destruirlos, impidiendo que aparezcan en la generación siguiente. El factor de supervivencia ( $k_s$ ) indica la probabilidad de supervivencia del esquema tras ser sometido a los operadores cruce y mutación. Su valor exacto es difícil de calcular, pero puede ser acotado analizando cómo actúan los operadores.

El cruce en un SGA es monopunto; se realiza escogiendo una posición (punto de cruzamiento) e intercambiando entre las cadenas progenitoras las subcadenas que quedan a cada lado del punto de cruzamiento. En un SGA el criterio de reemplazo empleado es el *reemplazo inmediato*, por el que la descendencia sustituye a los progenitores. De esta forma las cadenas seleccionadas para un cruce son sustituidas por las cadenas resultantes del cruce.




Figura 4.7: Posibles puntos de ruptura de un esquema. Adaptado de [Santamarina, 95].

Es posible determinar la probabilidad de que las cadenas representadas por un esquema determinado  $\mathbf{H}$ , sobrevivan al operador cruce apareciendo en la siguiente generación. Si  $k$  es la longitud de las cadenas, existen  $k-1$  posibles puntos de cruzamiento. Un punto de cruzamiento determinado provocará la ruptura del esquema, si se encuentra entre el primer y el último gen fijo (diferente de #) del esquema (Figura 4.7). Así pues, el número de posibles puntos de ruptura de  $\mathbf{H}$  es  $\delta(\mathbf{H})$ , definido anteriormente como la longitud del esquema.

La probabilidad de que una cadena sea sometida a cruzamiento es un parámetro del algoritmo denotado por  $P_c$ . Esto permite determinar que la probabilidad de que un esquema sobreviva a la aplicación del operador cruzamiento, y aparezca en la siguiente generación, es:

$$P_s(H) \geq 1 - P_c \frac{\delta(H)}{k-1}$$

El otro operador a considerar en la supervivencia de los esquemas es la mutación. En los SGA ésta se produce cambiando el valor de un determinado gen por otro alelo. Para que un determinado esquema  $H$  sobreviva, no debe alterarse el valor de ninguno de los genes fijos. Así pues, la mutación no debe afectar a ninguno de los  $\alpha(H)$  elementos distintos de  $\#$  del esquema. La probabilidad de que una cadena de la población mute vendrá dada por un parámetro del algoritmo denominado probabilidad de mutación ( $P_m$ ).

Dado que cada esquema cuenta con  $\alpha(H)$  elementos fijos que no deben mutar, la probabilidad de que un determinado esquema sobreviva tras la mutación puede expresarse como:

$$P_m(H) = (1 - P_m)^{\alpha(H)}$$

Dado que la probabilidad de mutación suele muy inferior a la unidad ( $P_m \ll 1$ ), la expresión anterior puede tomar la forma:

$$P_m(H) \approx 1 - P_m \cdot \alpha(H)$$

Combinando las expresiones obtenidas para el cruce y la mutación podemos estimar la capacidad de un esquema para sobrevivir a la aplicación de los operadores genéticos, es decir  $k_s$ :

$$k_s \geq \left(1 - P_c \frac{\delta(H)}{k-1}\right) (1 - P_m \cdot \alpha(H)) \approx 1 - P_c \frac{\delta(H)}{k-1} - P_m \cdot \alpha(H)$$

Conocidos los factores  $k_g$  y  $k_s$ , ya es posible estimar el número de cadenas representadas por un esquema  $H$  que existirán en la siguiente generación de un algoritmo genético básico:

$$m(H, g + 1) = m(H, g) k_g k_s \geq m(H, g) \frac{\mu(H)}{\mu} \left[1 - P_c \frac{\delta(H)}{k-1} - P_m \cdot \alpha(H)\right]$$

donde:

- $m(\mathbf{H},g)$  es el número de cadenas de una población representadas por un determinado esquema  $\mathbf{H}$  en la generación  $g$
- $\mu(\mathbf{H})$  es la adaptación media de las cadenas representadas por  $\mathbf{H}$  en la generación  $g$ .
- $\bar{\mu}$  es la adaptación media de todas las cadenas presentes en la población en la generación  $g$ .
- $P_c$  es la probabilidad de cruzamiento empleada en el algoritmo
- $\delta(\mathbf{H})$  es la longitud del esquema  $\mathbf{H}$
- $k$  es la longitud de las cadenas que componen la población
- $P_m$  es la probabilidad de mutación empleada en el algoritmo
- $o(\mathbf{H})$  es el orden del esquema  $\mathbf{H}$

Esta expresión constituye el Teorema Fundamental de los Algoritmos Genéticos, que podría enunciarse diciendo, que tras la actuación de los operadores genéticos básicos sobre una población de cadenas en una generación  $g$ , el número de cadenas representadas por un esquema determinado ( $\mathbf{H}$ ) esperado en la generación  $g+1$ , viene dado por la expresión anterior.

A partir de lo expuesto pueden extraerse las siguientes conclusiones válidas en la práctica [Pérez, 04]:

- La evolución de la presencia de un esquema en la población, es una progresión geométrica que depende del grado de adaptación de las cadenas representadas por el esquema ( $k_g$ ), y de la longitud y del orden del mismo ( $k_s$ ). Los esquemas con una adaptación relativa superior a la media ( $k_g > 1$ ) evolucionarán aumentando su presencia en la población, disminuyendo la de los esquemas menos adaptados. Asimismo, los esquemas más cortos y de menor orden, harán que  $k_s$  se aproxime a 1, aumentando las probabilidades de supervivencia.
- La selección permite incrementar la presencia de esquemas bien adaptados en la población, reduciendo la presencia de los menos válidos. La selección no provoca la aparición de nuevos esquemas en la población.
- El operador cruce permite el intercambio de información entre individuos. La información con más probabilidad de compartirse es la que se presenta en forma de esquemas cortos y de bajo orden. Este operador puede provocar la aparición de nuevos esquemas en la población. Es el operador fundamental de los algoritmos genéticos.
- El operador mutación introduce variabilidad en la población. Puede provocar la aparición de nuevos esquemas y la desaparición de otros. Puede considerarse



un operador secundario con respecto al cruce.

Los algoritmos genéticos exploran el espacio de soluciones mediante la yuxtaposición de esquemas bien adaptados, cortos y de bajo orden. A este tipo de esquemas se les denomina **bloques constructivos** [Srinivas et al., 94b; Pérez, 04].

#### 4.4.3 El paralelismo implícito de los algoritmos genéticos

Como se ha indicado en el apartado anterior, cada cadena de una población de  $P$  cadenas de longitud  $k$ , puede ser representada por  $2^k$  esquemas. Para que una cadena sea representada por un esquema, basta con que en cada componente el esquema tenga el mismo alelo que la cadena o bien un símbolo # (Figura 4.8).

En una población, cuyos elementos pueden tomar  $a$  valores diferentes, existen entre  $a^k$  y  $P \cdot a^k$  esquemas distintos. Algunos de estos esquemas (sobre todo los bloques constructivos) serán procesados de modo útil, aumentando su presencia y sobreviviendo a la aplicación de los operadores genéticos.

Holland fue capaz de determinar, asumiendo una serie de hipótesis generales [Goldberg, 89a], que aunque en principio un algoritmo genético procesa sólo  $P$  cadenas en cada generación, se obtiene información útil de al menos  $P^3$  esquemas, y por lo tanto de las cadenas por ellos representadas. Es decir, en el proceso evolutivo secuencial se estudian en cada paso  $P$  cadenas, pero simultánea y paralelamente se estudian  $P^3$  esquemas. Esta propiedad de búsqueda en paralelo, denominada paralelismo implícito, es la que proporciona mayor robustez a los algoritmos genéticos en comparación con otras técnicas de búsqueda ciega.

El planteamiento seguido por Holland para llegar a esta conclusión (según [Santamarina, 95]) es el siguiente:

Dada una población de  $P$  cadenas sometidas a un SGA, es posible determinar la longitud de los esquemas  $\delta(H)$  cuyo porcentaje de supervivencia sea uno concreto, por ejemplo, del 40%, mediante la expresión:

$$1 - P_c \frac{\delta(H)}{k - 1} - P_m \cdot o(H) = 0,4$$

Llamando  $k_p$  a dicha longitud, es posible afirmar que aquellos esquemas cuya longitud  $\delta(H)$  sea menor o igual que  $k_p$ , tendrán un porcentaje de supervivencia mayor o igual a 40%, puesto que los esquemas de menor longitud

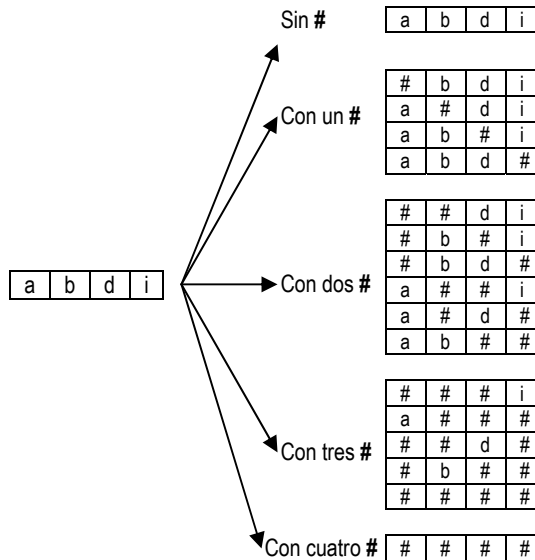


Figura 4.8: Los dieciséis esquemas representativos de una cadena de longitud cuatro.

tendrán mayores posibilidades de sobrevivir. A partir de esta premisa, Holland plantea la cuestión de determinar cuántos de esos esquemas con  $\delta(H) \leq k_p$ , son realmente procesados cada generación en una población de  $P$  cadenas.

Para poder establecer un estimador del límite inferior de la cantidad de esquemas procesados, Holland estudió el orden de los esquemas como característica que le sirviera para diferenciarlos y cuantiarlos. En primer lugar estableció el límite superior como:

$$P \cdot 2^{k_p+1} \cdot (k - (k_p+1) + 1)$$

El número de esquemas de longitud  $\delta(H) \leq k_p$  sigue una distribución binomial, por lo que la mitad de ellos poseerán un orden inferior a  $(k_p+1)/2$  y la otra mitad superior. Llamando  $P_p$  al número de estos últimos, es posible determinar que:

$$P_p = \frac{P \cdot 2^{k_p+1} \cdot (k - (k_p+1) + 1)}{2} = P \cdot 2^{k_p} \cdot (k - (k_p+1) + 1)$$

Así,  $P_p$  es un estimador que proporciona un límite inferior del número de esquemas de longitud  $\delta(H) \leq k_p$  que se procesan en una población de  $P$  cadenas. Es un límite inferior dado que sólo considera aquellos esquemas cuyo orden es superior a  $(k_p+1)/2$ . Si se da a  $P$  un valor adecuado,  $P=2^{k_p/2}$ , se obtiene que:

$$P_p = (k - (k_p+1) + 1) \cdot P^3$$

indicador que depende del tamaño de la población al cubo.

#### 4.4.4 Limitaciones del algoritmo genético básico y de su base teórica

El algoritmo genético básico (SGA), sobre el que se asienta el desarrollo del teorema de Holland y la hipótesis de los bloques constructivos, posee limitaciones evidentes. Estas limitaciones son debidas fundamentalmente, a que la codificación de los individuos de la población debe realizarse empleando un alfabeto de signos binario, a que no contempla la inclusión de restricciones en la búsqueda, y a que el algoritmo es absolutamente ciego, sin poseer ningún tipo de información o conocimiento específico del problema.

El SCA es un método ineficiente de resolución de problemas. Aunque es muy general y capaz de afrontar de forma eficaz una gran diversidad de problemas, como contrapartida es poco eficiente en la resolución de los mismos. Esta ineficiencia proviene fundamentalmente de la falta de conocimiento específico del problema que se resuelve.

Por otra parte, esta opacidad provoca que en algunos casos no se cumpla la hipótesis de los bloques constructivos, ocurriendo que combinaciones de bloques constructivos de elevada aptitud, generen individuos de baja calidad. Esto puede provocar la *desorientación*

del algoritmo, dado que la única información que guía la búsqueda es precisamente la obtenida de la aptitud de los individuos generados. Este problema puede solucionarse proporcionando al algoritmo alguna información de calidad que colabore en el guiado de la búsqueda.

El factor que más influye en el incumplimiento de la hipótesis de los bloques constructivos, es la definición de la función de aptitud. El SGA funciona recomblando esquemas cortos y de bajo orden, si la definición de la función de aptitud provoca que la solución óptima pueda ser representada por esquemas de ese tipo, el SGA será capaz de localizarla. Sin embargo, si la definición de la función provoca que los esquemas cortos de bajo orden no sean representativos de la cadena óptima, el SGA será incapaz de localizar dicha solución. A este tipo de funciones se les denomina *desorientadas* (deceptive functions) [Goldberg, 89a]. Este fenómeno se ve incrementado cuando existe una fuerte interrelación entre dos o más genes, provocando que la contribución de un gen a la aptitud de un individuo dependa de los valores que adopten esos otros genes. A este fenómeno se le denomina *epistasia*<sup>24</sup>, y provoca que sea difícil la generación de bloques constructivos apropiados [Pérez, 04].

Como se ha indicado en el apartado anterior el cruce en un SGA es monopunto; se realiza escogiendo una posición (punto de cruzamiento) e intercambiando entre las cadenas progenitoras las subcadenas que quedan a cada lado del punto de cruzamiento. La selección de este tipo de cruce es coherente con la hipótesis de los bloques constructivos, dado que permite una alta conservación de los esquemas al mantener en la descendencia elementos consecutivos de los padres. Sin embargo, la afirmación de Holland de que éste es el tipo de cruce que ofrece mejores resultados no ha podido ser probado en la literatura. Más aún, determinados experimentos han concluido que el cruce uniforme (selección de un bit de cada padre con igual probabilidad) ofrece mejores resultados que el cruce monopunto [Syswerda, 89], lo cual parece contradecir la hipótesis de los bloques constructivos .

Otro de los problemas del algoritmo genético básico, es la alta probabilidad de que se produzca una convergencia prematura de la población hacia un óptimo local. La aparición en fases evolutivas tempranas de individuos significativamente más aptos que el resto de la población (superindividuos), puede provocar una evolución en avalancha de los mismos. Los individuos significativamente más aptos serán favorecidos en la selección, aumentando su presencia en la población. Dado que el tamaño de la población es finito disminuye la diversidad. Esto puede repetirse durante varias generaciones, dominando completamente la población estos superindividuos. Bajo estas circunstancias, los procedimientos de cruce estandarizados no son capaces de generar individuos que mejoren la aptitud de sus padres. Más bien, los operadores de cruce se limitan a regenerar a los progenitores actuales. El proceso de optimización queda, en estas circunstancias, en manos de la mutación bit a bit [Fogel et al., 94].

La convergencia prematura puede ocurrir además por otro motivo. Dada la imperfección del proceso de muestreo, ante poblaciones pequeñas formadas por individuos con aptitudes parecidas, un individuo puede verse favorecido por la selección en sucesivas ocasiones.

---

<sup>24</sup> El empleo del término *epistasia* es debido a la analogía del fenómeno con el que ocurre en la naturaleza. La epistasia es la interacción entre los productos de dos genes situados en dos *loci* diferentes, en la que un gen impide la expresión fenotípica del otro.

Esto puede dar lugar a que dicho individuo acabe dominando la población y provocando la convergencia prematura. Este fenómeno, conocido como *deriva genética* es más probable en poblaciones pequeñas, con poca diversidad de aptitudes entre los individuos que la forman [Pérez, 04].

Estos inconvenientes y limitaciones del SGA pueden solventarse introduciendo modificaciones en el algoritmo básico. Las variaciones más comunes buscan introducir conocimiento específico del problema a resolver. De esta manera el algoritmo obtenido perderá parte de su generalidad; será válido para resolver un número limitado de problemas, ganando a cambio eficiencia en la resolución de los mismos. Esto puede lograrse de diversas maneras: utilizando codificaciones de las soluciones adaptadas al problema, proporcionando mecanismos de tratamiento de individuos no factibles, introduciendo restricciones a las soluciones, construyendo nuevos operadores genéticos u operadores adaptados al problema, implementando sistemas de adaptación automática de parámetros en función de la evolución de la población o, en los casos extremos, creando algoritmos híbridos con otras técnicas heurísticas o metaheurísticas.

#### **4.5. Codificación de las soluciones**

Como se ha visto, de manera estricta, la codificación de las soluciones en un algoritmo genético debe realizarse de forma binaria. Aunque sobre esto existe una cierta discusión en la bibliografía, en principio el rendimiento del algoritmo es mayor cuando los genes pueden adoptar un número de valores (alelos) reducido [Holland, 75], dado que de esta manera existe una mayor variedad de esquemas en la población para una longitud dada. Llevando esta premisa al extremo la codificación ideal constará de sólo dos alelos (0,1). Además, este tipo de representaciones facilita la aplicación de los operadores genéticos básicos, sobre todo en el caso de la mutación.

Goldberg enunció dos principios fundamentales que debe cumplir una codificación [Goldberg, 89a]:

**Principio de los bloques constructivos con significado:** Las características de los individuos relevantes en la aptitud de las soluciones, o lo que es lo mismo, las zonas del espacio de búsqueda más adecuadas para la obtención de las mejores soluciones, deben poder expresarse mediante esquemas cortos y de bajo orden, es decir, mediante bloques constructivos que expresen esas características.

**Principio del alfabeto de símbolos mínimo:** El conjunto de elementos escogidos para la codificación de las soluciones, debe ser el más pequeño posible, asegurando la adecuada representación del problema original.

Se considera que una codificación representa de manera adecuada un problema cuando posee estas cinco propiedades [Pérez, 04]:

- **Compleitud:** Cualquier solución del problema debe poder ser representada mediante esa codificación.
- **Coherencia:** Cualquier cadena formada mediante esa codificación debe representar una solución al problema.

- **Uniformidad:** Todas las soluciones deben poder ser representadas por un número igual de codificaciones, evitando que unas lo estén más o menos que otras. Puede exigirse una relación biunívoca entre el espacio de las cadenas y el espacio de las soluciones: cada cadena representa una y sólo una solución, y cada solución es representada por una y sólo una cadena.
- **Localidad:** Debe existir proporcionalidad entre las variaciones de las codificaciones y las variaciones de los individuos representados. Si se producen pequeños cambios en las cadenas, deben producirse pequeños cambios en las soluciones, asimismo, grandes cambios en las cadenas darán lugar a importantes cambios en las soluciones.
- **Sencillez:** La codificación y descodificación de los individuos debe ser un proceso sencillo.

La codificación binaria no resulta adecuada para la mayoría de problemas de búsqueda, puesto que no siempre es posible encontrar una codificación que dé significación a cada uno de los elementos que forma la cadena. En la práctica, lograr una codificación binaria perfecta que posea las cinco características anteriores resulta imposible. Por otra parte, en caso de que se lograra dicha codificación binaria perfecta, sería muy difícil que cumpliera el principio de los bloques constructivos con significado y evitara la aparición de epistasis (ver 4.4.4). Éste es el caso de gran parte de los problemas de ingeniería en los que se requiere una elevada precisión numérica. La representación binaria puede, en estos casos, originar individuos de gran tamaño que requieren grandes capacidades de cómputo y almacenamiento, y que no permitan la aparición de esquemas significativos, cortos y de bajo orden. Por otra parte, individuos representados por cadenas extremadamente largas, hacen aumentar el tamaño del espacio de posibles soluciones, lo que según Zbigniew Michalewicz [Michalewicz, 92] hace disminuir el rendimiento de los algoritmos genéticos.

Este autor propuso una representación alternativa (matrices, listas, árboles, vectores de reales...) más cercana al problema y de mayor significación. Estas modificaciones proporcionan cierto conocimiento específico al algoritmo, que aunque disminuyen su generalidad respecto a los algoritmos genéticos, aumentan su eficiencia en la consideración de restricciones importantes y en la resolución de problemas de optimización numérica. Por otra parte, como apunta Davis en [Davis, 91], los parámetros de los problemas son en la mayor parte de los casos numéricos, y representarlos directamente en formato entero o real en lugar de binario, hace más fácil comprender e implementar el problema, y dar un sentido a los operadores genéticos adaptándolos al problema en cuestión.

Como ya se indicó en el capítulo anterior, algunos autores proponen que los algoritmos que emplean estas codificaciones de mayor significación, y que poseen cierto conocimiento específico del problema, sean una categoría particular dentro de la computación evolutiva que denominan *programas de evolución* [Michalewicz, 92; Pérez, 04; Romero et al., 04], sin embargo, la mayor parte coincide en incluirlos como una variante de los algoritmos genéticos [Spears et al., 93; Fogel, 94; Santamarina, 95].

La codificación no-binaria parece ofrecer resultados, que en muchos casos, superan los obtenidos mediante codificaciones binarias. La explicación a este fenómeno no es sencilla. Michalewicz indica que la introducción de conocimiento específico del problema suple la disminución de paralelismo. En otros casos se ha reinterpretado el concepto de esquema

para explicar esta circunstancia [Antonisse, 89; Radcliffe, 91a; Radcliffe, 91b]. Goldberg presentó una teoría para tratar de explicar porqué representaciones de alta cardinalidad ofrecen tan buenos resultados [Goldberg, 91]. Esta teoría, llamada *teoría de los alfabetos virtuales*, explica que el conjunto de alelos que son empleados en la codificación de los individuos converge en las primeras iteraciones a un conjunto más pequeño, reduciendo el número de alelos efectivos y disminuyendo así la cardinalidad del conjunto.

#### **4.6. Creación de la población inicial**

De forma general esta población inicial es generada de manera aleatoria, aunque en algunos casos se realiza mediante el uso de técnicas heurísticas. Es conveniente que esta población sea lo más variada posible, conteniendo individuos de características muy diferentes. Por otra parte, debe tratarse que el número de cadenas que representan individuos no factibles sea lo más reducido posible.

En problemas muy restringidos puede resultar difícil localizar una cantidad suficiente de individuos factibles, como para completar una población inicial de determinado tamaño. Por otra parte, emplear tamaños pequeños de población suele concentrar la búsqueda del algoritmo en zonas pequeñas del espacio de soluciones [Brad et al., 96], y hace disminuir la diversidad. Este problema puede resolverse empleando tamaños de población variable. En este tipo de estrategias el tamaño de la población va aumentando o disminuyendo en función del grado de convergencia de la población. Así, es posible emplear un tamaño pequeño para la población inicial que facilite localizar suficientes individuos factibles y, posteriormente aumentar el tamaño. El tamaño de población inconstante es empleado también en ciertas variantes de los algoritmos genéticos que limitan el tiempo de supervivencia de los individuos introduciendo el concepto de 'edad' del mismo (este tema se tratará en 4.8.1.4).

La velocidad de convergencia del algoritmo puede depender en gran medida de la población inicial escogida. Una población inicial poco variada puede dar lugar a fenómenos de deriva genética, y una en la que un individuo es especialmente bueno (superindividuo) puede provocar la convergencia prematura hacia óptimos locales (ver 4.4.4).

#### **4.7. La función de evaluación y la función de aptitud**

Para poder evolucionar hacia poblaciones cada vez más adaptadas al entorno es necesario conocer el grado de aptitud de los individuos, es decir, tiene que poderse evaluar cada individuo y ser comparado con el resto de la población. El mecanismo de selección posterior dependerá de la medición de la aptitud de los individuos. En este sentido cabe distinguir entre función de evaluación y función de aptitud.

El resultado de la **función de evaluación** es lo que se persigue maximizar (o minimizar). Es en sí el objeto del problema planteado. Sin embargo, en ocasiones no es posible o conveniente emplear dicha función para evaluar los individuos en un algoritmo genético.

Puede no ser sencillo expresar de manera numérica el objetivo perseguido en la resolución del problema, y en caso de conseguirlo, la expresión de la función puede ser

excesivamente compleja y difícil de implementar informáticamente. Entre los cálculos realizados por un ordenador para la ejecución del algoritmo, aquellos destinados a evaluar los individuos son, con diferencia, los que más tiempo de proceso requieren. Así pues, debe tratarse de simplificar en lo posible la expresión de la función de evaluación. Es interesante destacar, que los algoritmos genéticos obtienen buenos resultados con funciones de aptitud que son simplificaciones de las de evaluación. Es decir, son suficientemente insensibles al error como para permitir utilizar expresiones simplificadas mediante, por ejemplo, la linealización.

Inconvenientes añadidos al empleo de una función de evaluación pura en el algoritmo, son la necesidad de que ésta deba devolver siempre valores positivos y que, en algunos casos, se debe minimizar el valor obtenido en lugar de maximizarlo. La necesidad de que los valores devueltos por la función sean positivos, es debida a que ésta es una de las hipótesis de partida sobre las que se asienta el teorema de Holland.

Por lo tanto, se somete a la función de evaluación a una serie de transformaciones que facilitan su uso en el algoritmo. Las más habituales son el desplazamiento y el escalado.

#### 4.7.1 Desplazamiento y escalado

Para la evaluación de los individuos se emplea la **función de aptitud** (fitness), que es una función derivada de la función de evaluación mediante los mecanismos de desplazamiento y escalado entre otros. El **desplazamiento** permite obtener funciones de aptitud cuyo conjunto imagen sea siempre positivo. El procedimiento de desplazamiento más empleado es [Pérez, 04]:

$$F_a(\mathbf{x}) = F - F_e(\mathbf{x}) \quad ; \quad \forall \mathbf{x} \in P$$

donde:

- $\mathbf{x}$  es un individuo de la población  $P$ ;
- $F_a$  es la función de aptitud;
- $F_e$  es la función de evaluación;
- $F$  es una cota superior de los posibles valores de  $F_e$  para cualquier individuo y en cualquier generación.

Dado que es posible que a priori no se conozca una cota superior de las posibles evaluaciones, en ocasiones se emplea para  $F$  el mayor valor obtenido hasta el momento. Esta adaptación dinámica debe realizarse con la frecuencia suficiente para evitar la aparición de deriva genética (ver 4.4.4).

El escalado pretende adaptar la presión selectiva a la fase de evolución del algoritmo. En las fases iniciales la función debe ser subescalada para evitar que la aparición de superindividuos provoque la convergencia prematura (ver 4.4.4). Es decir, que las diferencias de valoración deben minimizarse, para evitar que individuos excepcionalmente buenos dominen completamente la población. En fases posteriores, cuando la población

prácticamente ha convergido, es necesaria una valoración que incremente las diferencias de aptitud, para acentuar las características que hacen mejores a unos individuos que a otros. Se evita de esta forma, que la uniformidad de la población desemboque en una evolución errática. Forrest en 1985 [Goldberg, 89a] y posteriormente Srinivas [Srinivas et al., 94b] realizan una recopilación de los métodos de escalado más habituales.

#### 4.7.1.1 El escalado lineal

El escalado lineal calcula la aptitud a partir de la función de evaluación mediante la siguiente expresión

$$F_a(x) = a \cdot F_e(x) + b$$

donde **a** y **b** son constantes que se recalculan en cada generación.

El objetivo del escalado lineal es que las diferencias de aptitud entre los individuos sean menores en las primeras etapas de evolución (subescalado), y mayores en etapas tardías (sobrescalado). De esta manera se pretende evitar la dominación de la población por superindividuos en etapas tempranas y la deriva genética en las tardías.

Para lograr el objetivo, los parámetros **a** y **b** deben calcularse cumpliendo dos condiciones. La primera es que los valores medios de las funciones de evaluación y aptitud deben coincidir, lo cual se traduce en que:

$$b \equiv (1 - a) \cdot \bar{F}_e$$

donde  $\bar{F}_e$  es el valor medio de la función de evaluación en la población.

La segunda condición pretende controlar el rango de valores entre la aptitud del mejor individuo y la aptitud media. Esta condición se expresa mediante:

$$\max(F_a(x))_{\forall x \in P} \equiv C \cdot \bar{F}_e$$

donde **C** es un parámetro de control que suele tomar valores entre 1,5 y 2. A partir de esta expresión es posible determinar el valor **a**.

La aplicación de esta condición puede hacer aparecer individuos con aptitudes negativas. En algunos casos este problema se resuelve eliminando de la competición a dichos individuos. En otros, se sustituye la segunda condición por:

$$\min(F_a(x))_{\forall x \in P} \equiv 0$$

#### 4.7.1.2 El truncado $\sigma$

Esta forma de escalado aplica la transformación:

$$F_a(x) \equiv F_e(x) - \bar{F}_e + c \cdot \sigma$$

$\sigma$  es la desviación típica de los valores de la función de evaluación de la población, y **c** es una constante que suele tomar valores entre 1 y 3. La aparición de individuos con



aptitudes negativas se soluciona asignándoles discrecionalmente un valor nulo.

De la misma forma que el escalado lineal, la aplicación del truncado  $\sigma$  evita la sobreinfluencia de los superindividuos al comienzo del proceso evolutivo, y aumenta la selectividad en fases de convergencia de la población.

#### **4.7.1.3 El escalado potencial o ley potencial del escalado**

El escalado potencial eleva el valor de la función de evaluación a una potencia  $k$  cercana a uno. Aunque su valor depende en gran medida del problema a resolver, un valor típico es 1,005.

$$F_a(x) \equiv F_e(x)^k$$

### **4.8. Los operadores genéticos**

Es lógico, y así sucede en la naturaleza, que para que las poblaciones evolucionen hacia una mayor adaptación a su entorno, los individuos de cada generación deban ser sustituidos por otros que recojan aquellas características exitosas de sus progenitores. No obstante, esto no es suficiente si se pretende mejorar la adaptación de la especie. Se hace necesario que los nuevos individuos aporten características fenéticas novedosas, obtenidas de la combinación de la carga genética de sus progenitores, o de la aparición de cambios aleatorios en su codificación genética. Esta tarea es asumida en los algoritmos genéticos por los operadores genéticos.

Existe una gran diversidad de operadores genéticos, resultantes en la mayor parte de adaptaciones al problema particular que se trata de resolver. Sin embargo, los tres operadores básicos característicos de los algoritmos genéticos son: la selección, el cruce y la mutación. Cada uno de ellos desempeña un papel fundamental en la mejora de la aptitud de las poblaciones; el operador selección es análogo a los procesos competitivos para lograr la supervivencia y el apareamiento; el cruce es análogo a la combinación de las cargas genéticas de los individuos que se aparean y reproducen; y la mutación simula las alteraciones que por diversas causas se producen en el código genético de algunos individuos.

#### **4.8.1 El proceso de selección y reemplazo**

En la naturaleza los individuos mejor adaptados al medio tienen más probabilidades de reproducirse y de sobrevivir durante varias generaciones. De esta manera mantienen y diseminan en la población las estructuras genéticas que desarrollan fenotipos exitosos. Los individuos menos aptos encuentran más dificultades para reproducirse y su esperanza de vida es menor. A este proceso se le denomina Selección Natural<sup>25</sup> y permite que cada

---

<sup>25</sup> La teoría de la Selección Natural fue desarrollada por Charles Darwin y fue publicada en 1859 en el libro *"El Origen de las Especies"*. Sin embargo, ya en 1858 se hizo pública en un documento

generación mejore su adaptabilidad con respecto a las generaciones precedentes, dando lugar a la evolución de las especies.

En la analogía con la Naturaleza planteada en la estructura y principios de funcionamiento de los algoritmos genéticos, dicho proceso de Selección Natural se realiza mediante dos procedimientos: la *selección* propiamente dicha y el *reemplazo*.

El proceso de selección elige un subconjunto de la población formado por aquellos individuos que conformarán, por diversas vías, la siguiente generación. Los procesos en los que interviene la selección son: la generación de la población de criadores, la selección de los supervivientes y, en caso de que se emplee una estrategia elitista, la selección de la élite.

Aunque existen múltiples variantes, en el Algoritmo Genético Básico (ver 4.4.2) el proceso de selección comienza escogiendo a los individuos de la población que servirán de *criadores*. De entre estos individuos (que forman una población auxiliar o intermedia) se selecciona a los que efectivamente se reproducirán. Este conjunto de operaciones es la *Selección* propiamente dicha. El proceso de escoger aquellos individuos de entre la población intermedia y los descendientes que formarán la nueva generación por sustitución de la antigua, se denomina *Reemplazo*.

En los apartados siguientes se realiza un recorrido, necesariamente incompleto, por diferentes tipos de procesos de selección y reemplazo. Una más exhaustiva enumeración puede encontrarse en [Goldberg, 89a; Chambers, 95a; Chambers, 95b; Chambers, 99].

#### 4.8.1.1 Tipos de procesos de selección

La selección puede llevarse a cabo por **muestreo directo**, es decir, escogiendo a los individuos en base a una regla fija (los *n* mejores, los *n* peores,...). Este tipo de muestreo es muy poco empleado, puesto que su carácter determinista contradice la filosofía inherente a los algoritmos genéticos. Su uso fundamental se centra en la selección de la élite en las estrategias elitistas.

Los muestreos aleatorios son los más empleados, pudiéndose encontrar en la literatura abundantes planteamientos [Schell, 98]. El **muestreo aleatorio simple** asigna la misma probabilidad de selección a cada uno de los individuos, mientras que el **muestro estocástico** asigna la probabilidad de selección en base a la aptitud de los individuos. A mayor aptitud, mayor probabilidad de resultar escogido. Algunas variantes introducen en el muestreo estocástico ciertas peculiaridades [Pérez, 04]: el **muestreo diferenciado**, en el que cada individuo sólo puede ser seleccionado una vez, el **muestro conservador**, en el que se otorga alguna probabilidad de ser escogido a todos los individuos (no existe la probabilidad nula), y el **muestro excluyente**, en el que algunos individuos son excluidos a priori del proceso selectivo. El **muestreo por valor esperado** asigna un contador a cada individuo inicializado a un valor determinado. Cada vez que un individuo es seleccionado para reproducirse se decrementa su contador, siendo excluido de posteriores muestreos cuando su contador llega a cero. Al procedimiento de selección que emplea este tipo de muestreo se le denomina **selección por contadores**.

---

presentado al mismo tiempo que Alfred Russel Wallace, quien había llegado de manera independiente a plantear la misma teoría.

Los mecanismos de muestreo estocástico más habituales son: el sorteo, muestreo por restos, por torneos y por ruleta, siendo éste último el más empleado. El muestreo **universal** o **por ruleta** (roulette wheel selection) [Goldberg, 89a] se lleva a cabo asignando a cada individuo una probabilidad que podría ser representada por un sector de una ruleta (de ahí el nombre del método de muestreo). A mayor adaptación del individuo, mayor es el sector que le corresponde en la ruleta y, por tanto, mayor probabilidad de resultar escogido. Aunque existen varios procedimientos de cálculo de las probabilidades de cada individuo, el más habitual es el siguiente:

Sea  $x_i$  un individuo perteneciente a una población de  $p$  individuos. Sea  $\mu(x_i)$  la aptitud de  $x_i$  obtenida mediante la correspondiente función de aptitud. La probabilidad de selección de  $x_i$  se calcula mediante la expresión:

$$P(x_i) = \frac{\mu(x_i)}{\sum_{j=1}^p \mu(x_j)}$$

Una vez conocidas las probabilidades de cada individuo, estos se ordenan de mayor a menor probabilidad. Una vez ordenados se calculan las probabilidades acumuladas de cada uno, como la suma de la probabilidad propia y la de todos los que le preceden en esa ordenación.

$$P_{\text{acum}}(x_i) = \sum_{j=1}^i P(x_j)$$

De esta manera se obtienen una serie de intervalos consecutivos, comprendidos entre 0 y 1, cuyo tamaño es proporcional a la aptitud de cada individuo. Para seleccionar un individuo se genera un número aleatorio entre 0 y 1 (en la analogía se hace girar la ruleta) y se selecciona al individuo cuyo intervalo contiene dicho número aleatorio. Esto se apreciará más claramente mediante un ejemplo.

Sea una población de 4 individuos  $\{x_1, x_2, x_3, x_4\}$  cuyas aptitudes son 2, 10, 3, y 9 respectivamente. La suma de las aptitudes de la población es 24, por lo que las probabilidades de cada individuo son 0,083, 0,416, 0,125 y 0,375 respectivamente. La ordenación de los individuos según probabilidad decreciente proporciona la secuencia  $\{x_2, x_4, x_3, x_1\}$ . Las probabilidades acumuladas de dicha secuencia serán 0,416, 0,791, 0,916 y 1 respectivamente. Al generar un número aleatorio  $a$  entre 0 y 1, será seleccionado el individuo que cumpla el siguiente criterio:

$x_2$  si  $a \in [0, 0,416]$ ;

$x_4$  si  $a \in ] 0,416, 0,791]$ ;

$x_3$  si  $a \in ] 0,791, 0,916]$ ;

$x_1$  si  $a \in ] 0,916, 1]$ ;

Como puede apreciarse, el tamaño del intervalo es mayor cuanto mayor sea la aptitud del individuo. Análogamente, el sector de la ruleta correspondiente a cada individuo aumenta

con la aptitud del mismo (Figura 4.9).

Esta forma de selección es la más empleada puesto que sigue la filosofía de los algoritmos genéticos: los individuos mejor adaptados tienen más probabilidades de ser seleccionados, sin embargo, dado que es un número aleatorio el que decide la selección, todos los individuos tienen alguna probabilidad de ser seleccionados, incluso los peor adaptados. Esto que en principio puede parecer no deseable, introduce variabilidad en la población, mantiene ciertas características de los individuos que, en el futuro, combinadas con las de otros elementos de la población, pueden resultar exitosas, y es un factor más para evitar la convergencia prematura del algoritmo.




Figura 4.9: Selección por Ruleta.

La selección por ruleta tal y como se ha expuesto en los párrafos anteriores, puede presentar problemas cuando uno o varios individuos presentan aptitudes muy diferentes a las del resto de la población. En esos casos, los superindividuos acaparan la mayor parte de la probabilidad de selección, teniendo el resto de la población pocas posibilidades de ser seleccionado. Si en la población de 4 individuos del ejemplo anterior, la aptitud de  $x_2$  fuera 50, este individuo ocuparía el 85% de la ruleta, quedando un 15% para el resto de la población.

El **Rank Selection** (selección por clasificación), es una forma alternativa de selección que permite solucionar ese problema. En este caso, una vez calculadas las aptitudes de los individuos de la población, se ordenan éstos de menor a mayor calificación. Se otorga a cada individuo una puntuación igual a la posición que ocupa en esa clasificación: uno al primero, dos al segundo,..., y  $p$  al último; siendo  $p$  el tamaño de la población. Por último, se calculan las probabilidades de selección de la misma forma que en la selección por ruleta, empleando las puntuaciones asignadas en la clasificación en lugar de las aptitudes.

Este procedimiento permite que todos los individuos de la población mantengan alguna probabilidad de ser seleccionados, y evita la convergencia prematura por las elevadas probabilidades de selección de los superindividuos. Como contrapartida, este sistema de selección ralentiza la convergencia, dado que las probabilidades de selección de los buenos individuos no diferirán mucho de las del resto, pudiendo desembocar en deriva genética de la población (ver 4.4.4).

Como ejemplo supongamos una población de cinco individuos  $\{x_1, x_2, x_3, x_4, x_5\}$ , cuyas aptitudes son, respectivamente: 30, 0,5, 290, 34 y 5,5. Si se emplea la selección por ruleta sin ranking, las probabilidades de selección de cada individuo son, respectivamente: 0,083, 0,001, 0,805, 0,094 y 0,015. En la Figura 4.10 (a) puede observarse que mientras que la probabilidad de selección del individuo  $x_3$  es muy elevada, el individuo  $x_2$  tiene una probabilidad prácticamente nula de ser escogido. Las probabilidades de  $x_1$ ,  $x_4$  y  $x_5$  son

también pequeñas en comparación con la del superindividuo  $x_3$ .

Aplicando Rank Selection las probabilidades de selección pasan a ser 0,200, 0,066, 0,333, 0,266 y 0,133 respectivamente. En la Figura 4.10 (b) puede observarse el reparto de probabilidades. Todos los individuos tienen probabilidad de ser escogidos, aunque las diferencias de probabilidad entre los individuos más y menos aptos han disminuido.




Figura 4.10: Probabilidades de selección con (a) y sin (b) Rank Selection.

#### 4.8.1.2 Procesos de reemplazo

El proceso de reemplazo no es más que la selección de los individuos que formarán la nueva generación por sustitución de los de la anterior. Esta diferenciación entre selección y

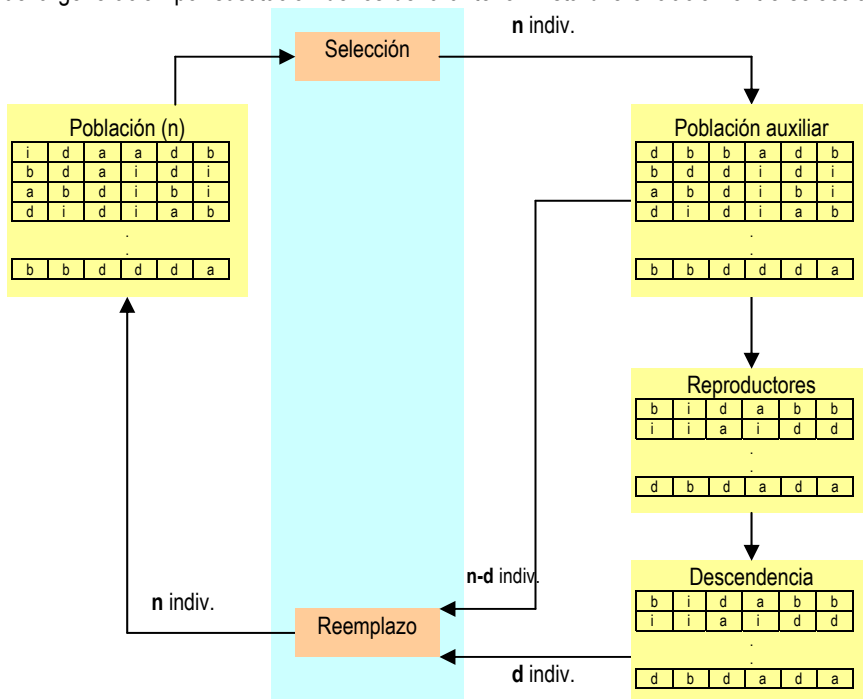


Figura 4.11: Proceso de selección-reemplazo en un SGA (adaptado de [Pérez, 04]).

reemplazo tiene sentido en los algoritmos que mantienen una población intermedia auxiliar entre generaciones, de la que se extrae los individuos de la nueva generación. Ejemplo de esto es el SGA, en el que dicha población auxiliar está formada por individuos seleccionados de la población (criadores), de la que a su vez se selecciona a los reproductores. El proceso de reemplazo selecciona a los individuos que sustituirán a los de la población anterior, de entre los de la población auxiliar y los descendientes de los reproductores (Figura 4.11).

El reemplazo puede llevarse a cabo de diferentes maneras. El más inmediato es que los descendientes sustituyan directamente a sus progenitores sin ninguna consideración previa. Este tipo de reemplazo es denominado **al vuelo** o **inmediato**. En otros casos los descendientes sustituyen a aquellos individuos de la población de criadores a los que más se asemejan, método denominado reemplazo por **factor de llenado**. El reemplazo **por inclusión** selecciona la nueva población de entre los progenitores y los descendientes. Por último, el reemplazo por **inserción** puede llevarse a cabo de dos maneras. Si el número de descendientes es suficientemente grande (mayor que el tamaño de la población), se conforma la nueva generación mediante la selección únicamente de descendientes, lo que provoca que un individuo no pueda subsistir más de una generación. Si el número de descendientes es inferior al tamaño de la población, se incluyen estos en la nueva generación, y se completa ésta con los mejores individuos de la población auxiliar.

#### 4.8.1.2.1 Estrategias elitistas

Se denomina élite de la población al individuo o grupo de individuos más destacable por su aptitud. Dado que el procedimiento de selección habitualmente empleado por los algoritmos genéticos implica cierto grado de aleatoriedad, no es posible garantizar que la élite sobreviva a la siguiente generación, y ni siquiera que sea seleccionada como reproductora. Así pues, es posible que las características deseables presentes en la élite desaparezcan de la población. Para evitar esto, las estrategias elitistas vinculan el tiempo de supervivencia de los individuos con su valor como solución al problema planteado.

El empleo de estrategias elitistas implica la selección del mejor o mejores individuos de la población, y su introducción de manera directa en la siguiente generación. Posteriormente, la selección de los criadores se realiza sobre los restantes miembros de la población y, a partir de estos, se genera el resto de la nueva generación (Figura 4.12).

El empleo de estrategias elitistas permite una exploración más profusa del espacio de soluciones en el entorno de la élite, pudiendo compararse con una intensificación local de la búsqueda, es decir, tienen tendencia a hacer la búsqueda más explotadora que exploradora. Su empleo mejora la convergencia del algoritmo, asegurando ésta teóricamente bajo ciertas condiciones muy generales. En caso de funciones de evaluación fuertemente multimodales (con muchos óptimos locales) su eficacia disminuye aumentando el riesgo de convergencia prematura.

El tamaño de la élite es un parámetro fundamental en la obtención de buenos resultados con esta estrategia. Es habitual emplear un tamaño de 1 ó 2 individuos élite por cada 50 individuos en la población; su empleo en poblaciones pequeñas puede resultar en convergencia prematura debido a la rápida disminución de la diversidad. Es recomendable, además, que las probabilidades de cruzamiento y mutación sean suficientemente grandes para evitar dicha convergencia prematura.

El uso de estrategias elitistas se considera imprescindible por ejemplo, cuando se emplean los algoritmos genéticos para la optimización de funciones en las que se pretende encontrar un óptimo global [De Jong, 93].

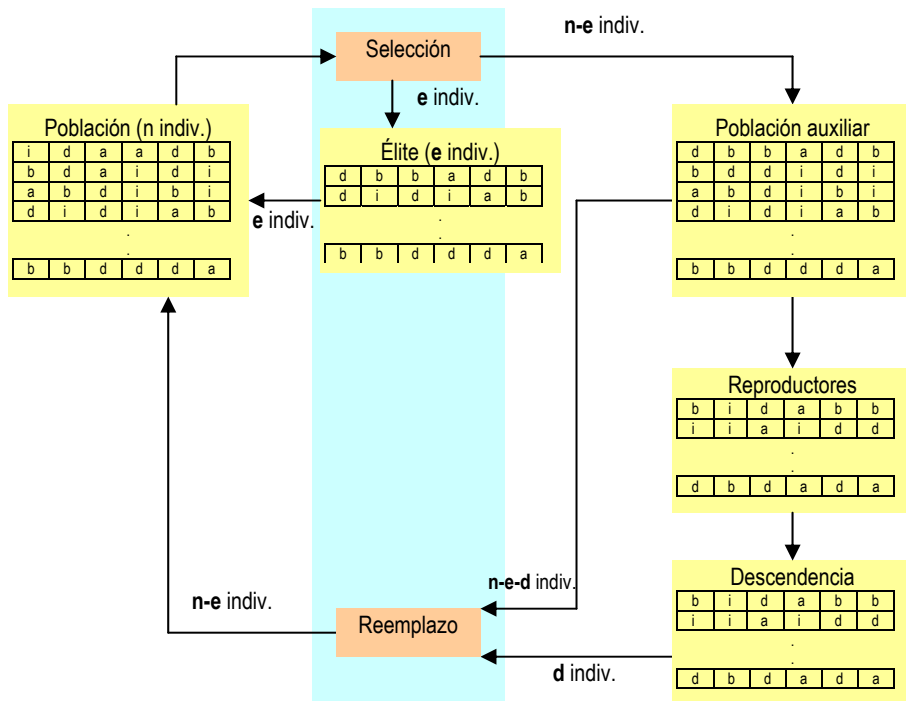


Figura 4.12: Esquema de la aplicación de una estrategia elitista.

#### 4.8.1.3 Algoritmos generacionales y de estado estacionario

El modelo de algoritmo visto hasta el momento realiza, en cada generación, un reemplazamiento total de la población (sin menoscabo de que determinados individuos sobrevivan de la generación anterior). Existe una clara diferenciación entre generaciones, pudiendo determinar dónde acaba una y comienza la siguiente. A este tipo de algoritmos se les denomina **generacionales**.

Como alternativa, los **algoritmos genéticos de estado estacionario**, realizan un reemplazo paulatino de los individuos. En estos, no se mantiene una población intermedia o auxiliar como tal. Se selecciona una cantidad pequeña de progenitores directamente de la población (no mayor de un 10% del número de individuos), los cuáles se cruzarán dando lugar a una descendencia que sustituirá, por reemplazo directo, a individuos de la población generalmente seleccionados mediante sorteo inverso. No se produce una sustitución completa de la población; se reemplaza constantemente una pequeña cantidad de individuos.

Los algoritmos genéticos de estado estacionario fueron propuestos de manera simultánea e independiente por Whitley y Syswerda [Whitley et al., 88; Syswerda, 89],

existiendo diferentes variaciones de estos algoritmos, fundamentalmente en la forma de realizar el reemplazo [Syswerda, 91].

Este tipo de algoritmos poseen la cualidad de mantener mejor la diversidad en la población, dado que conviven simultáneamente individuos de 'generaciones diferentes'. No es posible determinar donde acaba una generación y donde empieza la siguiente, se realiza un reemplazo paulatino que hace convivir a individuos de diferente antigüedad. Algunos estudios han probado de manera empírica, que los algoritmos genéticos de estado estacionario pueden resultar superiores a los generacionales en la resolución de determinados problemas, si se introduce en ellos un adecuado mecanismo de control de la población [Davis, 91].

Según Pérez en [Pérez, 04], los algoritmos de estado estacionario presentan las siguientes ventajas sobre los generacionales:

- Mayor insensibilidad a los errores de muestreo, que permite una asignación más precisa de las probabilidades de reproducción en función de la aptitud de los individuos.
- El método de reemplazo conlleva, de manera implícita, una estrategia elitista que hace perdurar a los individuos más aptos.
- Menor riesgo de convergencia prematura.
- Mantienen las condiciones del Teorema de Holland.

#### 4.8.1.4 La edad de los individuos

El contenido de este punto no trata en sí sobre un tipo concreto de mecanismo de selección o reemplazo, si no, más bien, de una modificación en la estructura del algoritmo que llega a hacer innecesario la introducción de procesos selectivos; de ahí su consideración en este punto del trabajo.

En 1994, Arabas y sus colaboradores [Arabas et al., 94] hicieron más completa la analogía con la naturaleza en la que se basa la computación evolutiva, introduciendo el concepto de *edad* de los individuos. Evidentemente, en la naturaleza los seres vivos no viven de manera indefinida<sup>26</sup>, la esperanza de vida de cada especie oscila en un intervalo de tiempo característico de dicha especie<sup>27</sup>. Dentro del ese intervalo, cada individuo de la especie podrá subsistir más o menos tiempo en función de su capacidad de supervivencia en el entorno, pero acabará finalmente desapareciendo y siendo substituido por otro individuo.

Trasladando esta idea a la computación evolutiva, Arabas propuso asignar a cada individuo, en el momento de su creación, una duración dependiente de su grado de aptitud.

---

<sup>26</sup> Se ha informado de la existencia de semillas viables después de más de 1000 años de enterramiento en tumbas del antiguo Egipto; por otra parte, determinadas células cancerosas pueden considerarse inmortales gracias a la enzima telomerasa. La duda consiste en si las semillas o las células cancerosas pueden englobarse en lo que genéricamente se denomina 'seres vivos'.

<sup>27</sup> En este sentido existe gran variedad: desde los pocos días de esperanza de vida de la *Drosophila Melanogaster* (mosca del vinagre), hasta la gran longevidad de determinados árboles (*Sequoia sempervirens* 1000, *Sequoiadendron giganteum* 2500 y *Pinus aristata* 3000 años).



Además, se le asigna un contador inicializado a 0 que aumenta conforme transcurren las generaciones. El valor de ese contador es la *edad* del individuo. Cuando la edad sobrepasa la duración asignada al individuo éste es eliminado de la población.

El proceso general puede observarse en la Figura 4.13. Definida una población inicial **P** de un tamaño determinado **p**, se asigna a cada individuo un contador con valor 0. Se evalúa la población para obtener la aptitud de cada individuo y, de manera proporcional a dicha aptitud, se asigna una duración a cada individuo.

De esta población inicial se seleccionan los individuos que se reproducirán. Este proceso no es en sí una selección propiamente dicha dado que se realiza de manera aleatoria. Todos los individuos tienen la misma probabilidad de ser escogidos. El número de individuos que se reproducirán y por lo tanto el tamaño de la descendencia, se obtiene generalmente mediante la expresión:

$$D(t) = \rho \cdot p(t)$$

que indica que el tamaño de la descendencia es función del tamaño de la población (que variará para cada generación).  $\rho$  es un parámetro que suele tomar un valor cercano a 0,4. Seleccionados los reproductores se crea la descendencia mediante cruce y se aplica a ésta el operador mutación. La descendencia es añadida sin más a la población y evaluada para obtener la duración de cada individuo.

Los contadores se incrementan una unidad y se comprueba si algún individuo ha superado su esperanza de vida. Si es así, estos individuos son eliminados de la población y el proceso vuelve a repetirse.

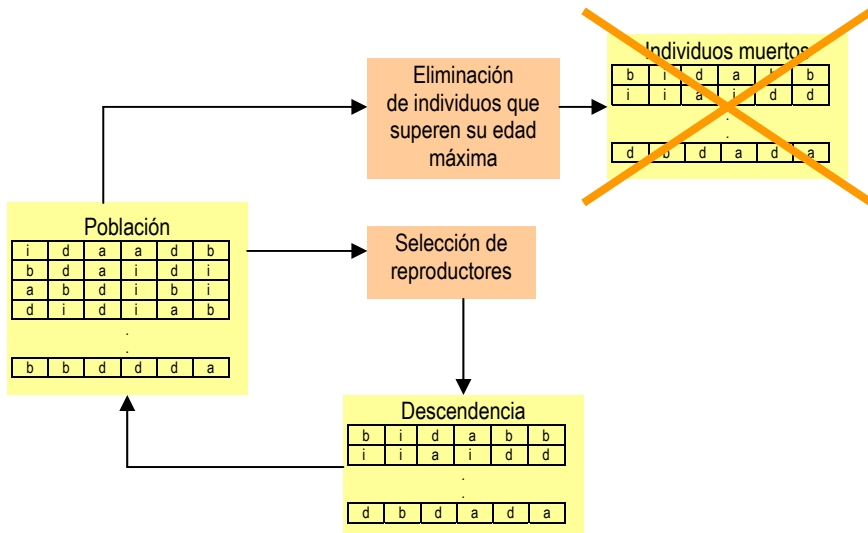


Figura 4.13: Esquema de un algoritmo genético con edades.

Como ya se ha indicado, el tamaño de la población es variable, dado que el número de descendientes que se incorporan a la población en cada generación, no coincide necesariamente con el número de individuos eliminados por haber alcanzado su esperanza de vida. Esto proporciona un eficiente mecanismo de autorregulación del tamaño de la población, parámetro éste fundamental para evitar la convergencia prematura y mantener la diversidad.

El tamaño de la población de este tipo de algoritmos presenta una evolución característica. Inicialmente existe mucha diversidad y la población crece. Cuando se localiza una buena solución el algoritmo converge y la población comienza a disminuir. Cada vez que se localiza un nuevo mejor resultado su produce un aumento brusco del tamaño de la población que poco a poco vuelve a disminuir.

Quizá el punto más crítico en la implantación de esta versión del algoritmo sea la asignación de la duración a cada individuo. Como ya se ha dicho, no existe un mecanismo de selección propiamente, puesto que los individuos se escogen de manera aleatoria; es la duración asignada a cada individuo la que determinará el tiempo que permanecerá en la población, y por tanto la mayor o menor posibilidad de ser escogido como reproductor. Así pues, el criterio para asignar la duración debe ser elegido cuidadosamente. En principio es necesario que los individuos más aptos posean duraciones mayores que los menos aptos, pero no es recomendable que exista una proporcionalidad directa entre aptitud y duración, puesto que esto podría causar el descontrol del tamaño de la población.

#### **4.8.2 Operadores genéticos; efecto de los operadores.**

Como se indicó en el apartado 4.8, en la naturaleza existen dos fuentes de variabilidad genética entre individuos de diferentes generaciones: la combinación de información genética procedente de dos individuos durante la reproducción, y la alteración aleatoria de genes debida a mutaciones. El operador selección por sí mismo no introduce variabilidad en la población, si no que más bien hace aumentar la presencia de los individuos mejor dotados en detrimento de la diversidad. La tarea de combinación de la información de diferentes individuos es asumida en los algoritmos genéticos por el operador cruce, y la variación aleatoria de la misma por el operador mutación.

El cruce es el operador por excelencia de los algoritmos genéticos [Holland, 75; Davis, 91]. Mediante este operador se consigue el intercambio de información genética entre individuos, mecanismo que combinado con la acción del operador selección, provoca la transmisión y combinación en las nuevas generaciones, de aquellos genotipos que se han expresado en fenotipos exitosos. A priori es imposible saber si las nuevas estructuras generadas poseerán una aptitud mayor que sus progenitores, pero la acción combinada de la selección y el cruce hace posible a la larga, identificar los bloques constructivos o grupos de genes que suponen características deseables en los individuos. El operador cruce produce la convergencia hacia las mejores combinaciones de la carga genética ya presentes en la población.

Los algoritmos genéticos son capaces de explorar y explotar el espacio de soluciones. Por explotar se entiende realizar una búsqueda exhaustiva en una zona restringida del espacio. Esta tarea se realiza mediante el operador cruce, que actúa como un intensificador de la búsqueda en la zona del espacio de soluciones actualmente ocupada por la población.

El efecto exploratorio, por el que se prospectan zonas del espacio alejadas de las soluciones presentes en la población, es asumido por el operador mutación. Como se representa gráficamente en la Figura 4.14, mientras la población converge hacia un óptimo local, esa zona del espacio de soluciones es estudiada, posteriormente, el operador mutación hace posible el salto hacia otros lugares inexplorados.

La mutación, salvo en algunas variantes, suele estar presente en casi todas las implementaciones de los algoritmos genéticos. Es frecuente considerarlo un operador secundario frente al cruce, introducido para asegurar que todos los alelos posibles entran alguna vez en la población, sin embargo, algunos autores discrepan otorgando a la mutación un papel preponderante [Hinterding et al., 95]. Este operador introduce la variabilidad genética aleatoria que contrarresta el efecto uniformizador del operador selección, y evita la convergencia hacia el primer óptimo local encontrado por el algoritmo. Por tanto, la mutación asume tareas diversificadoras de la población, y permite trasladar la búsqueda hacia zonas alejadas del espacio de soluciones (Figura 4.14).

Ajustando las probabilidades de cruce ( $P_c$ ) y de mutación ( $P_m$ ), es posible controlar el grado en el que actúa cada uno de los operadores genéticos. La probabilidad de cruce suele fijarse en el intervalo [0.6, 0.95] y la de mutación en valores mucho más bajos, menores de 0,1. Esta diferencia refleja, según algunos autores [Fogel et al., 94], la preponderancia del operador cruce frente a la mutación en los algoritmos genéticos.

En realidad la controversia sobre la importancia relativa entre estos dos operadores no ha sido zanjada. Los resultados empíricos muestran que para determinadas funciones objetivo, emplear sólo el operador mutación (sin cruce) es suficiente para obtener muy aceptables resultados. Sin embargo, para funciones objetivos en las que se produce un alto grado de epistasis (ver 4.4.4), el uso del cruce es absolutamente indispensable [Srinivas et al., 94b].




Figura 4.14: Efectos intensificadores y diversificadores de los operadores cruce y mutación.

### 4.8.2.1 El operador cruce

Puede abordarse el estudio del operador cruce desde una doble perspectiva: la *idea* y el *mecanismo* [Jones, 95]. La idea ya ha sido expuesta: esperar que los bloques constructivos de dos individuos se combinen en un descendiente, dando lugar a un individuo más apto que los progenitores. El mecanismo es el proceso por el que se lleva a la práctica la idea, la forma de implementar el cruce.

Existe una gran variedad de mecanismos, y a ellos se ha dedicado una gran cantidad de literatura. Desde la forma original y más simple (el cruce monopunto para cadenas binarias), los mecanismos de cruce han evolucionado buscando, en unos casos una mayor eficiencia, y en otros, adaptarse al tipo de codificación o al problema a resolver. A continuación se exponen algunos de los mecanismos de cruce más habituales.

#### 4.8.2.1.1 Cruce monopunto

Es el mecanismo más sencillo y el empleado en el algoritmo genético básico. En esta técnica, seleccionadas dos cadenas **a** y **b** de la población, de longitud  $I$ , que actuarán como progenitores, se escoge de manera aleatoria un escalár  $k \in [1, I]$ . Este valor es el denominado *punto de cruce*. Conocido éste se generan dos soluciones "hijas" formadas de la siguiente manera: la primera poseerá los  $k$  primeros genes de **a** y el resto de **b**, la otra solución hija se formará de manera inversa: con los  $k$  primeros genes de **b** y los restantes de **a**.




Figura 4.15: Cruce monopunto.

Como se indicó en 4.4.4, el funcionamiento de este tipo de cruce es coherente con la hipótesis de los bloques constructivos, dado que permite una alta conservación de los esquemas. Al mantener en la descendencia elementos consecutivos de los padres, se mantienen los esquemas de poca longitud. Sin embargo, esquemas de longitud elevada como el de la Figura 4.16, suponen un grave problema para este tipo de cruce. Sea cual sea el punto de cruce seleccionado, este esquema resultará roto y será imposible de transmitir a la descendencia. Así pues, existirán características de los padres que será imposible transmitir a la descendencia. Para solucionar este inconveniente se desarrolló el cruce bipunto.




Figura 4.16: Ejemplo de esquema no heredable mediante cruce monopunto.

#### 4.8.2.1.2 Cruce bipunto

En esta técnica, seleccionadas dos cadenas **a** y **b** de la población, de longitud  $I$ , que actuarán como progenitores, se escogen de manera aleatoria dos escalares  $k_1$  y  $k_2$

cumpliendo que  $1 \leq k_1 < k_2 \leq l$ . Conocidos los dos puntos de cruce, se generan dos soluciones "hijas" combinando los genes de **a** y **b**. El primer descendiente poseerá los  $k_1$  primeros genes de **a**, los  $k_1+1$  a  $k_2$  genes siguientes de **b**, y los restantes, de  $k_2+1$  a  $l$  serán de nuevo los genes correspondientes de **a**. El segundo descendiente se forma de manera análoga inversa.

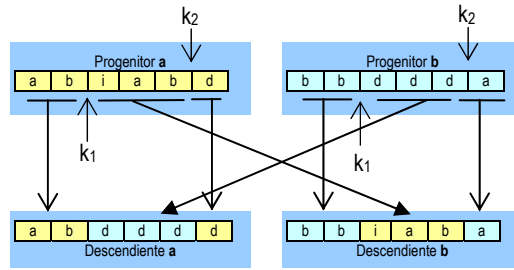


Figura 4.17: Cruce bipunto.

Puede comprobarse que el esquema representado en la Figura 4.16 es ahora heredable por la descendencia. Sin embargo, es posible localizar ahora combinaciones de genes que no podrían ser transmitidos a la descendencia mediante un cruce bipunto. Esto da lugar a generalizar este proceso en los cruces multipunto.

#### 4.8.2.1.3 Cruce multipunto

No son más que la generalización de los cruces antes mencionados. Se escogen ahora  $t$  puntos de cruce para obtener la descendencia por combinación alternada de los genes de los progenitores. El cruce monupunto y el bipunto son cruces multipunto con  $t=1$  y  $t=2$ .

La mejora en la capacidad de proceso de los esquemas que puede proporcionar aumentar el valor de  $t$ , se contrarresta con el aumento del tiempo de cálculo necesario para generar la descendencia. Además, De Jong, ya en 1975 (como se indica en [Goldberg, 89a]) concluyó tras una serie de experimentos, que introducir un número excesivo de puntos de corte reduce la eficacia del algoritmo, al producir la ruptura de la mayor parte de los esquemas. Elevar el valor de  $t$  supone realizar una búsqueda más exploratoria que explotadora.

#### 4.8.2.1.4 Cruce segmentado

Consiste en un cruce multipunto en el que el número de puntos de cruce es variable. En lugar de definir un valor concreto se define una probabilidad de que al llegar a cierto elemento de la cadena durante la reproducción, se introduzca o no un punto de cruce. A dicha probabilidad se le denomina *probabilidad de segmentación*. Por ejemplo; un valor de la probabilidad de segmentación de 0,15 indica que en promedio, el número de puntos de cruce en cada proceso reproductivo será  $0,15 \cdot l$  (siendo  $l$  la longitud de las cadenas), aunque no necesariamente tomará dicho valor.

#### 4.8.2.1.5 Cruce uniforme

El cruce uniforme se lleva a cabo generando una *máscara de cruce*. Esto no es más que una cadena de la misma longitud que las que se pretende cruzar, poblada aleatoriamente de ceros y unos. La generación de la descendencia es guiada por esa máscara. Uno de los hijos adoptará el valor de los genes del progenitor **a** en las posiciones en las que la máscara

contenga un uno, y los de **b** en aquellas posiciones en las que en la máscara haya un cero (Figura 4.18). El segundo hijo adoptará en cada posición los valores del progenitor contrario al del primer hijo.

El cruce uniforme realiza el intercambio de genes más que de grupos de genes, lo cual parece contradecir la hipótesis de los bloques constructivos. Lo que se realiza es el intercambio de atributos específicos independientemente de la posición que ocupen en la cadena. Esto puede resultar deseable en determinados tipos de problemas, y compensar la destrucción de esquemas que provoca su empleo.

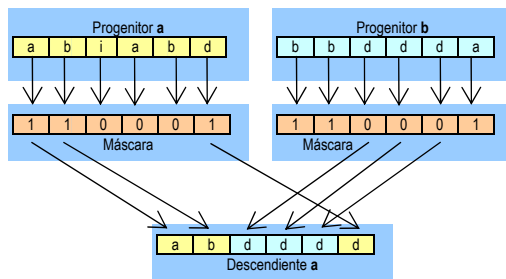


Figura 4.18: Generación de uno de los descendientes en un cruce uniforme.

Como se indicó en 4.4.4, determinados experimentos han concluido que el cruce uniforme ofrece mejores resultados que el cruce monopunto en determinadas tipologías de problemas [Syswerda, 89], sin embargo su uso debe adoptarse con precaución y cuando haya motivos fundados para hacerlo.

#### 4.8.2.1.6 Partially matched crossover (PMX) y cruce por orden

El primer tipo de cruce, descrito por Goldberg [Goldberg, 85; Goldberg, 89a], es adecuado para los problemas de orden como el del viajante de comercio. En estos problemas el valor de los genes es fijo y las soluciones son permutaciones de los elementos del alfabeto. La aptitud del individuo depende del orden en el que aparecen los genes en la cadena. En el caso del problema del viajante de comercio, los cromosomas tendrían tantos genes como ciudades se deben recorrer. Cada gen representa una ciudad, y el orden en el que aparecen en el cromosoma indica el orden en el que serán visitadas las ciudades. La aplicación de los operadores de cruce expuestos en los apartados anteriores generarían, con gran probabilidad, individuos no factibles. En el cruce PMX no se cruzan los valores de los genes si no, más bien, la posición que ocupan en la cadena.

Un tipo de cruce muy parecido descrito por Davis [Davis, 85], y aplicable al mismo tipo de problemas es el cruce por orden. La diferencia fundamental entre estos dos tipos de cruce y los expuestos anteriormente, es que estos incorporan conocimiento específico del problema a resolver. Esta adaptación del operador al problema permite convertirlos en operadores cerrados, es decir, operadores cuya aplicación producirá siempre individuos factibles. De esta manera los algoritmos son "menos" ciegos y resultan más eficientes en la resolución del problema concreto, pero, como contrapartida, pierden generalidad y reducen su ámbito de aplicación.

#### 4.8.2.1.7 Cruce sobre alfabetos de alta cardinalidad

Como se expuso en 4.5, la codificación de los individuos mediante alfabetos no binarios se ha extendido y obtenido buenos resultados, que superan en muchos casos a las

codificaciones de dos alelos. Entre estas codificaciones es de uso común el empleo de números enteros [Bramlette, 91] y números reales [Janikow et al., 91], que permiten la creación de operadores genéticos con cierto conocimiento del problema.

Surge así una gran variedad de operadores adaptados al problema a resolver, que actúan sobre individuos representados por cadenas en las que cada posición es un gen que puede adoptar valores enteros o reales. Ejemplos de operadores cruce de este estilo son el **average crossover**, que obtiene los genes del nuevo individuo como la media aritmética de los valores de los genes de los progenitores; el **geometric mean crossover**, que opera de forma similar pero empleando en este caso la media geométrica; o el **extensión crossover**, que obtiene la diferencia entre los valores de los genes de los progenitores, y se la suma al valor mayor o se la resta al menor.

#### 4.8.2.1.8 Mecanismos adicionales a los operadores de cruce

Los diferentes tipos de cruces expuestos pueden modificarse introduciendo mecanismos que permitan aumentar su rendimiento.

Puede considerarse la cadena cromosómica como una **estructura anular**, en la que el primer y el último gen resultan adyacentes. Otros sistemas desordenan aleatoriamente las posiciones de los genes de ambos progenitores antes de realizar el cruce, volviendo a ordenarlos realizado éste; este procedimiento es denominado **cruce con barajado**. Prohibir la aplicación de la mutación sobre los individuos generados por los cruces es otra alternativa denominada **cruce solitario**.

Un proceso más elaborado es el **cruce con adaptación**. En estos, la asignación de los puntos de cruce no se realiza de manera aleatoria, si no que sigue un proceso evolutivo análogo al del propio algoritmo. Los puntos de cruce que generan buena descendencia prosperan, los que no, desaparecen.

#### 4.8.2.1.9 Comparaciones de los diferentes tipos de cruce

Eshelman en 1989 [Eshelman et al., 89], realizó un exhaustivo trabajo de comparación entre diferentes tipologías de cruce, tanto teórica como experimentalmente. Se analizaron las desviaciones posicionales y distributivas de los cruces monopunto, bipunto, multipunto y uniforme entre otros. No fue posible extraer una conclusión respecto a qué técnica superaba en eficiencia a las demás. Las diferencias más grandes apreciadas entre los diferentes tipos de cruces no superaba el 20%.

Como ya se ha indicado, De Jong [Goldberg, 89a] fue muy crítico con los cruces multipunto, proponiendo el bipunto como el más eficiente. No obstante, cuando la población ha convergido mucho este tipo de cruce pierde su capacidad para incentivar la exploración del entorno del espacio de soluciones, dado que los segmentos procedentes de los progenitores tienen una alta probabilidad de ser parecidos. El mismo autor propuso una modificación al cruce bipunto en la que, si los segmentos a cruzar para generar la descendencia son parecidos, se escogen dos nuevos puntos de cruce.

Posteriormente, el mismo De Jong y sus colaboradores [De Jong et al., 90], concluyen que el cruce bipunto tiene un buen comportamiento para tamaños de población grande, pero

que para tamaños de población pequeños, el efecto de ruptura de esquemas producido por el cruce uniforme resulta beneficioso.

Parece pues, que no es posible afirmar taxativamente qué tipo de cruce es mejor. Simplemente se puede realizar alguna recomendación en función del tipo de problema a resolver. Sin embargo, dados los resultados de Eshelman, no parece que la elección del tipo de cruce sea una decisión crítica a la hora de implementar el algoritmo; no afectará a la eficacia aunque puede que sí afecte a la eficiencia del mismo.

#### 4.8.2.2 El operador mutación

En la naturaleza, la mutación es la alteración al azar del material genético (ADN en las células, y ADN y ARN en los virus), debida a errores en la transmisión durante la división celular, a radiaciones de ciertos tipos o a ciertas sustancias químicas denominadas agentes mutágenos. Salvo raras excepciones, las mutaciones suponen deficiencias en los individuos que las sufren y pueden llegar a ser letales. Sin embargo, comportan beneficios para la especie, ya que aportan variabilidad genética a la población que será el desencadenante de la selección natural.

Las mutaciones naturales pueden ser de tres tipos: *génicas*: alteraciones de la secuencia de nucleótidos de un gen, *cromosómicas*: alteraciones de la secuencia de genes de un cromosoma, y *genómicas*: alteraciones en el número de cromosomas. La analogía de la mutación en los algoritmos genéticos es implementada a través del operador mutación, que por su forma habitual de actuar puede considerarse como una mutación cromosómica.

La mutación se aplica sobre los individuos generados por el operador cruce. Aunque existen diversas variantes, la forma habitual de implementar el operador es la siguiente: para cada uno de los elementos de la cadena a mutar se escoge un número aleatorio comprendido entre 0 y 1. Si el valor obtenido es inferior a la probabilidad de mutación ( $P_m$ ) se produce el cambio del valor de ese elemento por otro alelo. Es decir, la probabilidad de que un elemento concreto mute es igual a  $P_m$ , que suele adoptar valores muy pequeños.

Suponiendo una representación binaria, un elemento puede tomar dos valores (0 y 1). En algunos casos la mutación se realiza cambiando el valor del elemento, es decir; si es cero se transforma en uno y viceversa. En otros casos se prefiere escoger aleatoriamente el valor que adoptará el elemento de la cadena, independientemente del valor inicial; en estos casos, la probabilidad de que el gen inicialmente seleccionado para mutar mute realmente es del 50%, dado que puede ser seleccionado de nuevo el valor original. De manera práctica, la aplicación de una u otra variante del operador no influye más que en la probabilidad de mutación efectiva.

La representación mediante alfabetos binarios de los individuos implica que cada gen (representante de una característica), debe ser codificado en varios elementos de la cadena si posee más de dos alelos posibles. La mutación, tal y como se ha definido, afecta a elementos de la cadena, a bits, más que a genes propiamente dichos. Algunas variantes de la mutación (*mutación sobre genes*), actúa sobre cada gen en lugar de sobre cada elemento de la cadena. En estos casos se escoge un alelo del gen, y se sustituyen los elementos que representan dicho gen por los correspondientes al nuevo alelo.



#### 4.8.2.2.1 Mutación sobre alfabetos de alta cardinalidad

De la misma forma que ocurre con el operador cruce (ver 4.8.2.1.7), la codificación de los individuos mediante alfabetos no binarios, ha hecho surgir una gran variedad de operadores adaptados al problema a resolver, que actúan sobre individuos representados por cadenas en las que cada posición es un gen que puede adoptar valores enteros o reales.

Ejemplos de operadores mutación de este estilo son el **random replacement**, que obtiene los genes a mutar del nuevo individuo de manera aleatoria; **creep mutation**, que añade o sustrae un valor pequeño aleatorio al valor del gen a mutar; o **geometric creep mutation**, que obtiene los nuevos valores multiplicando los antiguos por un número aleatorio cercano a la unidad.

En los dos últimos tipos de operadores los números aleatorios pueden generarse siguiendo distribuciones no necesariamente uniformes, como la exponencial, la normal o la binomial.

#### 4.8.2.2.2 Mutaciones por intercambio de posición

Este tipo de mutación es adecuado para los problemas de orden como el del viajante de comercio. Como se indicó para el caso de la mutación, en estos problemas el valor de los genes es fijo y las soluciones son permutaciones de los elementos del alfabeto. La aptitud del individuo depende del orden en el que aparecen los genes en la cadena. En el caso del problema del viajante de comercio, los cromosomas tendrían tantos genes como ciudades se deben recorrer. Cada gen representa una ciudad, y el orden en el que aparecen en el cromosoma indica el orden en el que serán visitadas las ciudades. En la mutación por intercambio de posición no se modifica el valor de los genes, dado que con gran probabilidad se generarían individuos no factibles al repetirse elementos en la cadena, si no que se intercambia la posición de los genes dos a dos. De esta manera se generan individuos factibles, dado que no aparecen ciudades repetidas y todas las ciudades están representadas en cada solución. El operador así definido es cerrado, siempre da lugar a individuos factibles si se parte de individuos factibles.

#### 4.8.2.2.3 Mutaciones no uniformes

La probabilidad de mutación ( $P_m$ ) es el valor que establece con qué probabilidad mutará cada uno de los elementos de una cadena. Este valor es idéntico para cada uno de los componentes o para cada uno de los genes de la misma.

La mutación no uniforme, introducida por Michalewicz, asigna probabilidades de mutación diferentes a cada elemento o gen que conforma el individuo. De esta manera se pueden establecer probabilidades adaptadas al significado de cada gen, proporcionando al algoritmo conocimiento específico del problema a resolver. Puede consultarse [Michalewicz, 92] para obtener información sobre diversos modos de asignar estas probabilidades

#### 4.8.2.3 El operador inversión

A diferencia de los operadores cruce y mutación, la inversión no es un operador que caracterice de una manera tan marcada a los algoritmos genéticos. Su presencia suele

darse, fundamentalmente, en algoritmos que emplean codificaciones binarias, como mecanismo para escapar de situaciones en las que se ha bloqueado el mecanismo de generación de bloques constructivos.

Como se expuso al tratar la hipótesis de los bloques constructivos (ver 4.4.2), el orden de los genes en el cromosoma es crítico para la constitución de dichos bloques. Se hace necesario para lograr el éxito en la búsqueda, que las regiones del espacio en las que se localizan soluciones de gran aptitud, puedan ser representadas por esquemas cortos y compactos. La ordenación seleccionada para codificar soluciones a un problema (el orden de los componentes que codifican los genes en el cromosoma), puede no resultar conveniente e impedir que se logre crear bloques constructivos adecuados, haciendo que el algoritmo sea incapaz de trasladar la búsqueda a las zonas más aptas del espacio de soluciones. Estas situaciones suelen desembocar en la imposibilidad de converger y en la desorientación.

Este inconveniente puede ser resuelto introduciendo en el proceso de optimización, no sólo el fenotipo de los individuos (lo que representan las estructuras), si no también el genotipo (las propias estructuras), es decir: buscar el orden de los componentes de la cadena que permita construir bloques constructivos de alto significado y con mayor potencial evolutivo [Goldberg, 89a].

Uno de los mecanismos que permite hacer evolucionar las estructuras de codificación es la inversión [Holland, 75]. Este operador actúa seleccionando aleatoriamente dos puntos de la cadena e invirtiendo el orden de los elementos existentes entre ambos. Se hace necesario que el algoritmo recuerde el significado original de cada uno de los elementos de la cadena durante los diferentes cambios de orden; esto puede hacerse mediante el etiquetado de los elementos (ver Figura 4.19). Cabe destacar que el proceso de inversión no modifica al individuo que representa el cromosoma, sino la forma en que dicho individuo es codificado<sup>28</sup>.




Figura 4.19: Actuación del operador inversión.

<sup>28</sup> En la naturaleza existe un mecanismo análogo por el que se modifica la estructura cromosómica, denominado evolución cariotípica. Puede decirse que la evolución cariotípica permite a las especies adoptar configuraciones cromosómicas que permitan una rápida adaptación a cambios bruscos en el entorno.

#### 4.9. Estrategias frente a los individuos no factibles

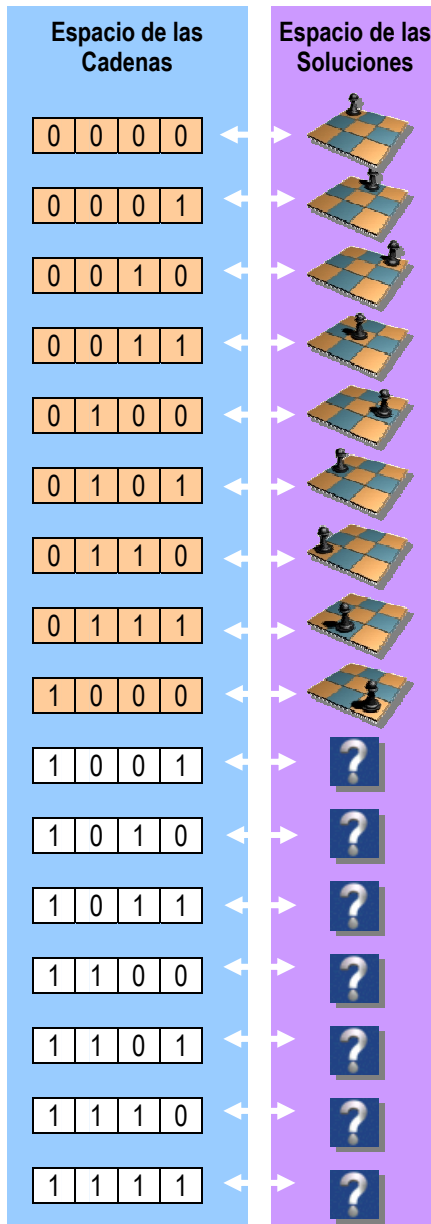


Figura 4.20: Cadenas representativas de individuos no factibles.

El algoritmo genético básico, tal y como fue definido en 4.4.2, es un método de búsqueda irrestrictiva. No es posible establecer límites o restricciones a la búsqueda puesto que no existen mecanismos para ello. Además del problema funcional que esto supone, representa, como ahora se verá, un grave problema operativo, que se da en los algoritmos que emplean codificaciones sobre un superconjunto del dominio del problema.

Como ejemplo considérese el algoritmo genético básico, en el que la codificación empleada para representar a los individuos (de longitud  $l$ ) es binaria. El conjunto de las cadenas de longitud  $l$  que pueden formarse con dicho alfabeto, es casi siempre mayor que el número de posibles individuos que representan soluciones al problema. Esto es, es posible formar cadenas que no representan individuos factibles que requerirán algún tipo de tratamiento.

Como ejemplo supongamos que un gen debe presentar 9 posibles alternativas; será necesario emplear 4 bits para codificar el gen. Sin embargo mediante 4 bits es posible codificar 16 alternativas, resultando que 7 cadenas no representan una alternativa válida.

Una adecuada codificación debe lograr que el espacio de posibles cadenas no sea mucho más grande que el espacio de soluciones, dado que de ser así se empleará gran cantidad de recursos en el tratamiento de las infactibilidades. Sin embargo, la elección de la forma de codificar los

individuos es en gran medida discrecional, y es imposible lograr hacer coincidir ambos espacios.

Cualquier tipo de técnica empleada para tratar los individuos no factibles que aparecen en la población durante la evolución, pasará necesariamente por incorporar, de manera directa o indirecta, conocimiento específico del problema. A continuación se expondrán las estrategias más habituales [De Jong, 85; Pérez, 04].

#### **4.9.1 Descarte o penalización**

La forma más inmediata de tratar los individuos no factibles es descartándolos (en un proceso también denominado filtrado); es decir, los individuos se generan sin un mecanismo que garantice su factibilidad, eliminando de la población los no factibles a posteriori. Por ejemplo, si el resultado del cruce de dos individuos produce un individuo no factible, éste simplemente se descarta. El descarte no es más que un caso extremo del sistema de penalización que a continuación se describe.

El sistema de penalización consiste en penalizar a los individuos no factibles. Esto se lleva a cabo modificando el valor de su función de aptitud de manera conveniente (aumentando o disminuyendo su valor según el problema sea a maximizar o a minimizar) de forma tal que se disminuya su probabilidad de supervivencia y reproducción. Es conveniente que el grado de penalización sea proporcional a la “cantidad de infactibilidad”, es decir, a lo apartada que esté una solución de la zona de soluciones factibles, sin embargo esto no es siempre fácil de medir, optándose entonces por penalizar en la misma medida a todas las soluciones no factibles.<sup>29</sup>

La intensidad de las penalizaciones influirá de manera decisiva en la evolución del algoritmo. Penalizaciones muy severas en problemas muy restringidos provocarán que se dispare el tiempo empleado en el procesamiento de las no factibilidades. Por otra parte, una solución factible poseerá una aptitud mucho mayor que las infactibles, por lo que la aparición de un individuo válido provocará que éste domine inmediatamente la población, y se produzca una convergencia prematura. Esto va en contra de la misma filosofía de las penalizaciones, que pretende alcanzar buenas soluciones factibles a través de soluciones infactibles intermedias que posean esquemas deseables<sup>30</sup>. De la misma forma, penalizaciones demasiado someras pueden provocar que la búsqueda se centre en zonas del espacio donde se concentren soluciones no factibles, dado que a pesar de la penalización impuesta, su aptitud supera a la de individuos factibles.

##### **4.9.1.1 Funciones de penalización adaptativas**

El problema de establecer de manera adecuada el nivel de penalización, se complica aún más si se considera que es conveniente que las penalizaciones actúen más intensamente en las fases finales de la evolución que en las iniciales. En el inicio, la búsqueda debe estar poco restringida, dificultando paulatinamente la aparición de individuos

---

<sup>29</sup> Algunas propuestas actúan de manera inversa; en lugar de penalizar las soluciones infactibles se sobrevalora la aptitud de los individuos factibles. A este tipo de técnica se le denomina, *gratificación*.

<sup>30</sup> Puede establecerse cierta analogía entre este mecanismo, y la oscilación estratégica empleada en los algoritmos tabú descrita en el capítulo anterior.

infactibles conforme el algoritmo comienza a converger hacia buenas soluciones.

Este problema puede abordarse mediante el empleo de penalizaciones adaptadas al estado de la búsqueda, conocidas como penalizaciones adaptativas (*adaptive penalties*). Ejemplo de éstas son: la descrita en [Michalewicz, 92], que endurece las penalizaciones con el avance de la evolución, la de Farley [Reeves, 94], basada en una analogía con el método de relajación lagrangiana, o el empleo de heurísticas en la determinación de la intensidad de las penalizaciones como proponen Klinciewicz y Luss [Reeves, 94].

## 4.9.2 Reparación

Como se ha indicado en el apartado anterior, las técnicas de penalización desaprovechan la información contenida en los individuos no factibles. El algoritmo, por tanto, pierde eficiencia y capacidad exploratoria. Una alternativa a los mecanismos de penalización, consiste en permitir la generación de individuos no factibles, sometiéndolos posteriormente a un proceso de reparación que los devuelve a la zona de factibilidad.

Dos son los grandes inconvenientes de estas técnicas: por un lado la imposibilidad de encontrar un mecanismo lo suficientemente general, lo que obliga a desarrollar técnicas específicas para cada problema y, por otra parte, el gran consumo de recursos computacionales que conllevan dichos mecanismos.

El *remapping* es una de estas técnicas de reparación que actúa recodificando los individuos no factibles. Considérese el caso del apartado previo en el que un gen debe presentar 9 posibles alternativas, lo que hace necesario emplear 4 bits para codificarlo. El problema que surge es que mediante 4 bits es posible codificar 16 alternativas, resultando que 7 cadenas no representan una posibilidad válida (véase la Figura 4.20). El *remapping fijo* soluciona las

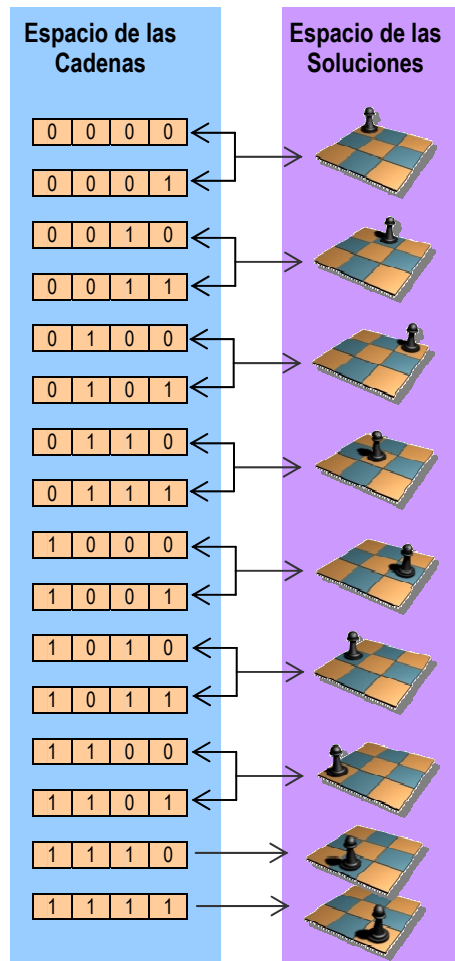


Figura 4.21: Resolución de infactibilidades mediante remapping fijo.

infactibilidades asignando a cada cadena infactible un individuo, aun a costa de que un individuo pueda ser representado por más de una cadena. En el ejemplo de la Figura 4.21, ocho individuos están representados por dos cadenas y dos individuos únicamente por una.

Mediante esta técnica cada cadena representa a un individuo factible, sin embargo, la posibilidad de los individuos representados por más de una cadena de aparecer y mantenerse en la población son mayores que la de los representados por una única cadena. Esto introduce desviaciones artificiales en la evolución de la población favorables a los individuos hiperrepresentados.

Como alternativa al remapping fijo, el *remapping aleatorio* actúa asignando al azar un individuo factible a las cadenas que representan individuos no factibles. Esto es: cuando aparece en la población una cadena que representa una infactibilidad, ésta es sustituida por cualquier cadena que represente a un individuo factible. Aunque este sistema elimina las desviaciones provocadas por el remapping fijo, deviene en una pérdida de la información transmitida entre padres e hijos durante el proceso reproductivo.

El *remapping probabilístico* es un sistema híbrido entre los dos anteriores. Cada posible valor de un gen (no únicamente los que están en exceso), es redirigido de manera probabilística a uno de dos posibles individuos factibles. De esta manera cada individuo tiene las mismas posibilidades de representación.

### 4.9.3 Codificación cerrada

Como se indicó en 4.5, las condiciones que debería cumplir un sistema de codificación óptimo son:

- **Compleitud:** Cualquier solución del problema debe poder ser representada mediante esa codificación.
- **Coherencia:** Cualquier cadena formada mediante esa codificación debe representar una solución al problema.
- **Uniformidad:** Todas las soluciones deben poder ser representadas por un número igual de codificaciones, evitando que unas lo estén más o menos que otras. Puede exigirse una relación biunívoca entre el espacio de las cadenas y el espacio de las soluciones: cada cadena representa una y sólo una solución, y cada solución es representada por una y sólo una cadena.
- **Localidad:** Debe existir proporcionalidad entre las variaciones de las codificaciones y las variaciones de los individuos representados. Si se producen pequeños cambios en las cadenas, deben producirse pequeños cambios en las soluciones, asimismo, grandes cambios en las cadenas darán lugar a importantes cambios en las soluciones.
- **Sencillez:** La codificación y descodificación de los individuos debe ser un proceso sencillo.

Si se logra una codificación que cumpla las condiciones de coherencia y uniformidad, se habrá logrado solucionar el problema de las infactibilidades. Hablando más propiamente, el problema no aparecerá, por lo que no es exacto hablar de una técnica para tratar los

individuos no factibles, sino para evitar su aparición.

Se trata de adoptar una codificación que impida la aparición de individuos no factibles, es decir, que el conjunto de las posibles cadenas sea igual al dominio del problema, y no un superconjunto del mismo. De esta manera, cualquier cadena generada representará un individuo factible. Se hace necesario, además, que los operadores genéticos sean cerrados, es decir, que de su aplicación se obtengan siempre individuos factibles.

Este sistema presenta inconvenientes similares a las técnicas de reparación: por un lado la imposibilidad de encontrar un mecanismo lo suficientemente general, lo que obliga a desarrollar técnicas específicas para cada problema y, por otra parte, el gran consumo de recursos computacionales que conllevan estos mecanismos.

#### **4.10. Parametrización de los algoritmos genéticos**

Siguiendo la imagen que plantean Srinivas y Patnaik [Srinivas et al., 94b], puede visualizarse el funcionamiento de los algoritmos genéticos, como una combinación equilibrada de exploración de nuevas zonas del espacio de soluciones y explotación de las zonas ya conocidas ... *“This balance, which critically controls the performance of the genetics algorithms, is determined by the right choice of control parameters: the crossover and mutation rates and the population size”*.

Estos autores apuntan lo que ya se ha comentado en apartados anteriores:

Aumentar la probabilidad de cruzamiento incrementa la recombinación de bloques constructivos y como contrapartida aumenta la rotura de cadenas de calidad. Incrementar la probabilidad de mutación aleatoriza la búsqueda, pero permite la reintroducción en la población de material genético desaparecido durante la evolución. Aumentar el tamaño de la población aumenta la diversidad y reduce la probabilidad de convergencia hacia óptimos locales, sin embargo, incrementa el tiempo de evolución necesario para converger hacia zonas óptimas del espacio de búsqueda.

La selección adecuada de los parámetros descritos no es una tarea trivial. Existen interacciones evidentes entre la actuación de los operadores genéticos y el tamaño de la población, que convierten a la parametrización en un complejo problema de optimización no lineal. Los parámetros adecuados dependen además fuertemente del tipo de función de aptitud empleada y, por tanto, del problema a resolver.

En [Srinivas et al., 94b] se indica que, aunque el tema de la adecuada parametrización de los algoritmos genéticos está lejos de ser resuelto, existen dos enfoques, expresados mediante dos sets de parámetros, que proporcionan, de manera general, buenos resultados. El primero, propuesto por De Jong y Spears [De Jong et al., 90] emplea tamaños de población grandes (100 individuos) y probabilidades bajas de cruzamiento y mutación ( $P_c=0,6$  ,  $P_m=0,001$ ). El segundo, sugerido en [Grefenstette, 86], propone tamaños de población menores (del orden de 30 individuos), con mayor actividad de los operadores genéticos ( $P_c=0,9$  ,  $P_m=0,01$ ).

El primer enfoque disminuye la actividad de los operadores manteniendo la diversidad gracias a una gran población. El segundo actúa a la inversa, una población pequeña que

evita la convergencia prematura por la actuación intensiva de los operadores genéticos. Ambas orientaciones proporcionan un papel preponderante a la actividad del operador cruce frente a la mutación.

Un estudio de la variación del rendimiento de los algoritmos en función de la parametrización establecida, puede encontrarse en [Digalakis et al., 00]. En este trabajo, se mide el rendimiento de los algoritmos en la optimización de 14 funciones referencia (benchmark) variando el tamaño de la población, el modo de realizar el reemplazo, la probabilidad de cruce y mutación, el tipo de selección, etc.

#### **4.10.1.1 Meta-algoritmos genéticos para la determinación de parámetros de ejecución**

Además de la parametrización adaptativa, que será tratada en el apartado siguiente, existen técnicas más o menos complejas que tratan de determinar los parámetros más adecuados para la resolución de un problema. En este sentido cabe destacar el empleo de meta-algoritmos genéticos [Grefenstette, 86].

Un meta-algoritmo genético es un algoritmo genético en el que cada individuo de la población es a su vez un algoritmo genético (ver Figura 4.22). Cada uno de estos individuos resuelve el mismo problema empleando parámetros diferentes. La bondad de las soluciones obtenidas por los individuos y la rapidez de convergencia mide la aptitud de cada uno. Los parámetros de ejecución evolucionan generación tras generación, hasta lograr converger a los parámetros “óptimos” de ejecución.

Evidentemente, este proceso es intensivo en el uso de recursos computacionales, teniendo sentido emplearlo únicamente cuando los resultados a obtener puedan ser reutilizados en múltiples ocasiones (resolución de muchos problemas similares bajo condiciones parecidas).

#### **4.10.2 Parametrización adaptativa**

Los valores óptimos de los parámetros del algoritmo varían durante la evolución de la población. Mientras que inicialmente puede ser deseable una elevada tasa de mutación, por ejemplo, puede preferirse que ésta disminuya cuando el algoritmo se encuentre cercano a converger a un óptimo <sup>31</sup>. Frente a la búsqueda a priori y fijación de los parámetros que controlan la evolución del algoritmo, existe la alternativa de emplear parámetros variables en función de las circunstancias evolutivas. Es lo que se denomina parametrización adaptativa. En 4.8.1.4 ya se expuso una técnica de reemplazo generacional (edad de los individuos), que hace que el tamaño de la población varíe en función del grado de convergencia del algoritmo. En [Srinivas et al., 94a] se encuentra una relación de técnicas que emplean este concepto de parámetro adaptable.

Ya en 1985, Davis [Davis, 85] introduce variaciones en las probabilidades de mutación y

---

<sup>31</sup> Existe una importante discusión en la bibliografía sobre la conveniencia de disminuir o aumentar la probabilidad de mutación durante la evolución. Ackley, Bramlette, Fogarty o Michalewicz, por ejemplo, defienden que ésta debe disminuir, aunque no ofrecen un motivo razonado para ello, basándose en la evidencia de sus experimentos. Puede aducirse que la mutación actúa como la temperatura en los algoritmos de recocido simulado, debiendo disminuir para favorecer la convergencia.



cruce en problemas de secuenciación de la producción. El sistema planteado hace variar de manera lineal las probabilidades, aumentando la de mutación y disminuyendo la de cruce, conforme avanza la evolución.

Aunque estrictamente no es un caso de parametrización adaptativa, en 1897 Schaffer y Morishma [Schaffer et al., 87] proponen un sistema de cruzamiento en el que la distribución de los puntos de cruce depende de la calidad de los individuos obtenidos. Esta información es codificada en una subcadena añadida a la cadena que representa a los individuos y participa de los operadores genéticos.

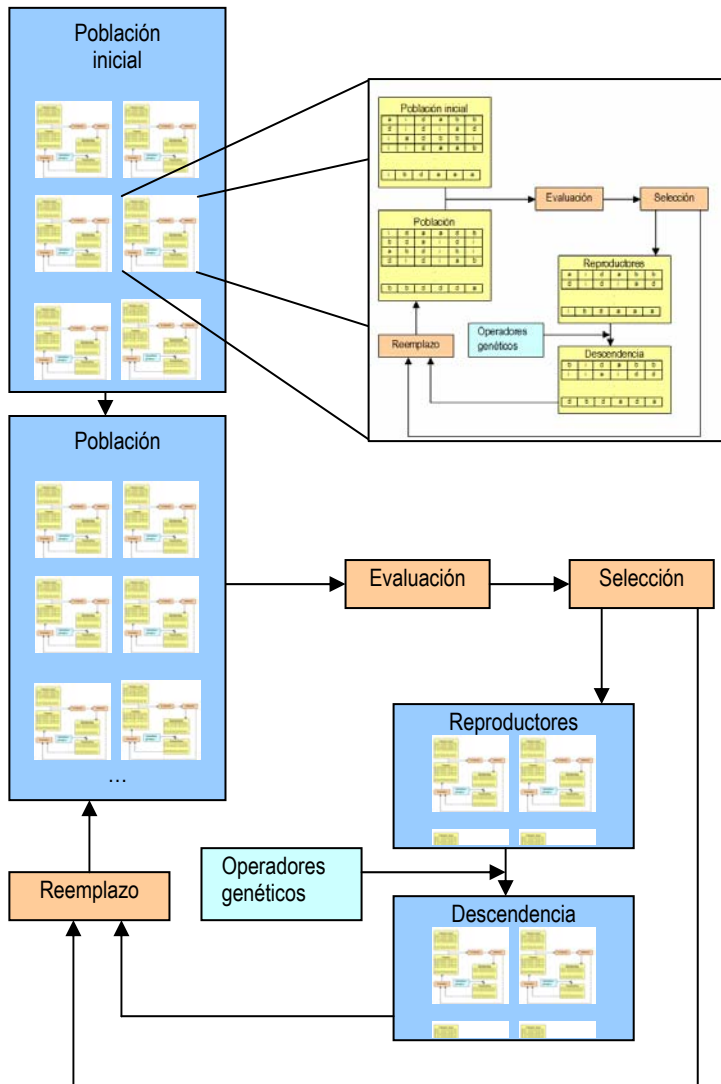


Figura 4.22: Meta-algoritmo genético. Los individuos de la población son, algoritmos genéticos.

Davis [Davis, 89; Davis, 91] propone un mecanismo en el que la probabilidad de actuación de un operador depende de la aptitud de las cadenas creadas por dicho operador. Las probabilidades son modificadas periódicamente, basándose en el rendimiento que ofrece la actuación de los operadores durante un periodo. Esta técnica es empleada habitualmente en los algoritmos de estado estacionario (ver 4.8.1.3) y parece proporcionar buenos resultados.

En [Fogarty, 89] y en [Whitley et al., 90] se introducen probabilidades de mutación adaptativas. En el primero se demuestra que la disminución exponencial de la probabilidad de mutación con las generaciones, produce buenos resultados en aplicaciones específicas con codificaciones enteras. En el segundo, la probabilidad de mutación depende de la distancia de Hamming<sup>32</sup> entre individuos. La diversidad en la población se asegura dado que la aparición de individuos similares provoca un aumento de la probabilidad de mutación y por tanto la reintroducción en la población de código genético perdido durante la evolución.

En [Srinivas et al., 94a] se propone un sistema adaptativo, en el que las probabilidades de mutación y cruce son calculadas y adaptadas para cada individuo concreto, en función de su aptitud. Esta propuesta es conceptualmente similar a la de Whitley, sin embargo, mientras aquella está enfocada a los algoritmos de estado estacionario la de Srinivas se centra en los algoritmos generacionales.

#### **4.11. Hibridación de los algoritmos genéticos**

Como ya se ha indicado anteriormente, los algoritmos genéticos son métodos débiles de búsqueda. La ventaja que supone su generalidad, y el que no necesiten apenas más información sobre el problema a resolver, que una manera de medir la bondad de las soluciones obtenida, tiene como contrapartida su ineficiencia y la imposibilidad del tratamiento de excepciones, como por ejemplo las infactibilidades. Así, cuando los algoritmos genéticos ortodoxamente definidos se emplean en la resolución de problemas con restricciones complejas (por ejemplo en ingeniería), pueden no ofrecer resultados mucho mejores que una búsqueda meramente aleatoria.

*“Traditional genetic algorithm, although robust, are generally not the most successful optimization algorithm on any particular domain”*<sup>33</sup> [Davis, 91].

Se ha indicado también que la forma de mejorar la eficiencia de los algoritmos genéticos es la incorporación al mismo de conocimiento específico del problema a resolver, aun a costa de que se pierda generalidad, robustez y el respaldo de la base teórica sobre la que se asientan. A pesar de esto último, en la realidad, la resolución de cualquier tipo de problema con una mínima dificultad mediante algoritmos genéticos se lleva a cabo necesariamente introduciendo este conocimiento. La incorporación del conocimiento puede realizarse de forma directa en el propio algoritmo (es el caso del empleo de codificaciones no binarias o

---

<sup>32</sup> La distancia de Hamming se calcula midiendo el número de bits distintos entre dos cadenas. En este contexto, trata de medir la diferencia entre dos individuos mediante la medición de las diferencias de las cadenas que los representan.

<sup>33</sup> “Los algoritmos genéticos tradicionales, aunque robustos, no son, generalmente, el algoritmo de optimización más exitoso en ningún ámbito particular”.

los programas de evolución [Michalewicz, 92]), o bien agregando al algoritmo procesos ajenos a su estructura básica. A este último caso se le denomina hibridación, y a los algoritmos así surgidos, algoritmos genéticos híbridos.

De manera general estos procesos añadidos suelen ser empleados en reforzar la búsqueda local del algoritmo. La estructura general del mismo realiza la búsqueda global, intensificándose la exploración en zonas específicas prometedoras empleando, por ejemplo, técnicas de escalada.

La hibridación suele implementarse de manera modular, y la ejecución puede ser paralela o secuencial [Pérez, 04]. En la ejecución **secuencial**, se realiza una búsqueda global sobre el espacio de soluciones para, en una segunda etapa, intensificar la búsqueda en los alrededores de las buenas soluciones localizadas. En la ejecución **paralela**, diversos módulos realizan búsquedas locales de manera simultánea, existiendo un procesador central encargado de recoger las soluciones obtenidas por estas búsquedas locales, y hacer evolucionar la población global.

Para la búsqueda local debe seleccionarse el procedimiento más adecuado al caso (según Davis, un algoritmo híbrido nunca será peor que el procedimiento con el que se hibrida el algoritmo genético). Si existe la posibilidad, se emplea alguna heurística de búsqueda local, en caso contrario puede emplearse otro tipo de técnicas. Se usa con frecuencia el Hill-Climbing<sup>34</sup>, llegando en casos a someter a cada individuo de la población inicial, y a cada nuevo individuo creado, a dicho proceso.

Una implementación tradicional de los algoritmos híbridos, introduce la búsqueda local en el proceso de reproducción, tratando de mejorar localmente los individuos obtenidos del cruzamiento [Davis, 91]. Si se encuentra una mejora, ese nuevo individuo se introduce en la población. Algunos autores critican esta forma de actuar, dado que el cambio en el código heredado de los padres supone también la pérdida de los esquemas heredados. Esto provoca la imposibilidad de una adecuada búsqueda paralela y hace perder su sentido al algoritmo.

En [Misevicius et al., 02] se presenta una técnica basada en la reconstrucción de soluciones mediante un procedimiento de mutación, que son sometidas posteriormente a un proceso de mejora. El mismo Misevicius presenta en [Misevicius, 03c] una nueva heurística cuya base es un algoritmo genético que emplea el principio de "*ruin & recreate*". Se basa en modificar (destruir/arruinar) de manera significativa las soluciones, para reconstruirlas posteriormente mediante una búsqueda local, realizando el proceso repetidas veces. El procedimiento suele obtener buenos resultados en los problemas de optimización complejos, muy restringidos, con funciones objetivo complicadas.

Los algoritmos híbridos han demostrado ser una importante herramienta para la resolución de problemas de distribución en planta dinámica. En estos problemas se considera que los flujos de materiales pueden variar debido, por ejemplo, a cambios en el proceso, y se trata de lograr una distribución de las actividades que minimice el coste de las posibles redistribuciones. Ejemplos de este tipo de aplicaciones pueden encontrarse en

---

<sup>34</sup> Estrategia de optimización local que sigue la dirección de mayor pendiente (positiva o negativa según el caso). Es muy útil si se posee una función heurística adecuada. Debido a su bajo coste computacional es muy empleada en optimización.

[Balakrishnan et al., 03b].

Una técnica genética de búsqueda local de especial interés es la **emulación del gradiente** [Goldberg, 89a], que permite reemplazar los procedimientos tradicionales de escalada por otros que actúan directamente sobre la codificación de los individuos. Se puede obtener una información parecida a la del gradiente conmutando los valores de los bits de un individuo. El procedimiento a seguir (como se ofrece en [Pérez, 04]) comienza seleccionando uno o más de los mejores individuos de la población. Se procede a conmutar uno por uno y sucesivamente todos los bits de los individuos interesados y a evaluar los resultados obtenidos. Se sustituyen en la población los individuos originales por los más aptos obtenidos en este proceso, continuando con la búsqueda genética.




Figura 4.23: Emulación del gradiente. El individuo original es sustituido por aquel que, obtenido variando el valor de un bit, proporcione un mayor descenso (ascenso) de la aptitud.

Puede consultarse una relación y comparación de algoritmos híbridos en [Maniezzo et al., 95] y en [Taillard et al., 01].

#### 4.11.1 Combinación de metaheurísticas en algoritmos híbridos

Los algoritmos híbridos fruto de la combinación de diferentes metaheurísticas, se encuentran entre las técnicas de resolución de problemas (y específicamente del problema cuadrático de asignación) que con más frecuencia aparecen en la literatura reciente [Loiola et al., 04]. Las diferentes combinaciones tratan de aprovechar las cualidades particulares de las diferentes metaheurísticas para obtener algoritmos eficientes en la resolución de problemas específicos. Se trata de aprovechar las cualidades de cada uno, compensando mutuamente sus debilidades, combinando de manera adecuada los elementos clave de las dos técnicas.

Por ejemplo, la oscilación estratégica propia de la búsqueda tabú (ver capítulo anterior), puede ser controlada por un algoritmo genético que cree un grado suficiente de diversidad que permita una transición efectiva entre las zonas de factibilidad y no factibilidad; el empleo

de estructuras de memoria típicas de los algoritmos de búsqueda tabú a los algoritmos genéticos, permite controlar el "historial" de los individuos de la población y, por ejemplo, hacer que estos sepan reaccionar de manera adecuada y adaptarse a situaciones conocidas.

Ejemplos de este tipo de algoritmos aplicados al problema cuadrático de asignación son las combinaciones de algoritmos genéticos con: algoritmos de recocido simulado [Koakutsu et al., 95; Bölte et al., 96], búsqueda tabú [Fleurent et al., 94; Glover et al., 95; Drezner, 03; Balakrishnan et al., 03b; Rodríguez et al., 04] o programación dinámica [Dunker et al., 05].



# 5

**Algoritmos genéticos aplicados al  
problema de la distribución en planta**

## 5. ALGORITMOS GENÉTICOS APLICADOS AL PROBLEMA DE LA DISTRIBUCIÓN EN PLANTA

### 5.1. Introducción

Dentro de las diferentes técnicas para la resolución del problema de la distribución en planta de las actividades industriales revisadas en capítulos precedentes, los algoritmos genéticos destacan por la abundante bibliografía existente [Loiola et al., 04], por los buenos resultados que proporcionan y por estar soportados por una base teórica sólida de la que carecen otras metaheurísticas.

La primera aproximación relevante al empleo de los algoritmos genéticos para la resolución del problema de la distribución en planta, es la propuesta realizada por Kar Tam Yan en 1992 [Tam, 92c]. La importancia de esta propuesta reside no únicamente en la aplicación de dicha metaheurística si no, además, en el planteamiento de una representación de tipo constructivo de las diferentes soluciones a través de árboles de corte, y en un sistema eficiente de codificación que permite su empleo en los algoritmos genéticos.

En el momento en el que Tam realiza su propuesta la mayor parte de las formulaciones del problema de la distribución en planta se realizan en forma de problema cuadrático de asignación. Entre otras, la limitación fundamental de este planteamiento para la resolución del problema de la distribución en planta de actividades industriales es la imposibilidad de considerar los requerimientos de área de las diferentes actividades. Para solventar este problema se desarrollaron planteamientos heurísticos de resolución.

Hasta ese momento habían aparecido numerosas heurísticas, tanto de tipo constructivo (CORELAP [Lee et al., 67], o ALDEP [Seehof et al., 67], por ejemplo) como de mejora (entre los que destaca CRAFT [Armour et al., 63]), que adolecían de dos limitaciones fundamentales: por un lado la búsqueda se realizaba desde un único punto del espacio de soluciones y, por otro, la consideración de restricciones geométricas era muy limitada.

CRAFT trata de solventar el segundo problema representando el espacio reservado a cada actividad mediante una colección de bloques adyacentes cuya área es igual al área de la actividad. El método de mejora se basaba en el intercambio de la posición de diferentes actividades. Sin embargo, para reducir la complejidad introducida por la división del dominio en pequeñas áreas unitarias sólo las actividades adyacentes o de igual área pueden ser intercambiadas, lo cual limita necesariamente el espacio de búsqueda y puede tener un impacto negativo en la calidad de la solución final obtenida. Por otra parte, la división del dominio en una rejilla proporciona una forma de satisfacer los requerimientos de área, pero no así las restricciones geométricas presentes normalmente en los problemas de distribución.

El primero de los problemas, la realización de la búsqueda desde un único punto del espacio de soluciones, provoca que el procedimiento quede atrapado fácilmente en óptimos locales. Tam desarrolló poco antes de su algoritmo genético un algoritmo de recocido simulado para evitar este problema, dada la capacidad de esta técnica para escapar de dicho tipo de óptimos [Tam, 92a], sin embargo es el propio Tam quien indica que ambas técnicas,



los métodos de búsqueda local y el recocido simulado, poseen dos inconvenientes fundamentales: tiempos de cómputo excesivamente elevados e incapacidad para aprender del espacio de soluciones explorado.

En su artículo "Genetic Algorithms, function optimization, and facility layout design", Tam trata de afrontar los dos problemas mencionados mediante el empleo de los algoritmos genéticos. La dificultad fundamental, la de codificar las soluciones como cadenas de longitud finita preservando el principio de los bloques constructivos con significado y el del alfabeto de símbolos mínimo [Goldberg, 89b], ya fue solventada por Tam en [Tam, 92a] aplicado a un algoritmo de recocido simulado.

Posteriormente son muchos los autores que realizan aportaciones en este campo. Algunas son modificaciones de mayor o menor entidad del algoritmo original, como la presentada posteriormente por el propio Tam [Tam et al., 98]; otras cambian radicalmente el enfoque, aportando nuevas formas de codificación de individuos, operadores genéticos mejorados o especializados, funciones de aptitud multicriterio, hibridación con otras metaheurísticas o técnicas de búsqueda local, etc. En definitiva, los algoritmos genéticos aplicados a la distribución en planta adoptan formulaciones muy diferentes: bidimensionales, multiplanta, discretas, continuas, empleando curvas de llenado de espacios, árboles de cortes, estructuras de bahías flexibles, etc. Una de esas técnicas, el algoritmo LAYAGEN de Santamarina [Santamarina, 95] sirve de base al presente trabajo, por lo que será expuesto con especial detalle en este capítulo.

## **5.2. Las propuestas de Tam**

En 1992 Kar Tam Yan presenta "*Genetic algorithms, function optimization, and facility layout design*", en el que se expone la aplicación de un algoritmo genético para la resolución del problema de distribución. Las diferentes distribuciones en planta son representadas como una estructura de cortes construida mediante la partición recursiva del dominio de la planta (Figura 5.8). Cada partición rectangular en la estructura de cortes corresponde al espacio destinado a cada departamento. Esta estructura de cortes es representada de manera equivalente mediante un árbol de cortes<sup>35</sup>.

En esta primera propuesta de Tam, el árbol de cortes empleado es determinado en una fase previa a la búsqueda genética, quedando profundamente determinada esta segunda fase por el árbol escogido. Así pues, el mismo autor junto a Chan [Tam et al., 98], realiza una segunda propuesta. Se indica en este segundo artículo que el empleo de un árbol de cortes fijo en el proceso de búsqueda de la distribución óptima, sólo puede cubrir una parte del espacio de posibles soluciones, el que determina el árbol de cortes localizado. En este nuevo procedimiento se establece la búsqueda del árbol de cortes y de la distribución adecuada en una sola fase, evitando la restricción a una zona concreta del espacio de soluciones.

Otra propuesta de Tam [Tam et al., 91] presenta un procedimiento jerárquico en el cuál las actividades son agrupadas en clusters usando el flujo de materiales como criterio de

---

<sup>35</sup> El empleo de árboles de corte para la representación de distribuciones en planta ya fue tratada en capítulos precedentes.

similitud. Cada uno de los grupos formados es distribuido en layouts independientes. Finalmente, y considerando a cada “sub-layout” como una gran actividad, se construye la distribución definitiva.

### 5.2.1 La primera propuesta de Tam

El procedimiento comienza por la determinación del árbol de cortes adecuado al problema. Este árbol será fijo, y empleado a lo largo de todo el resto del proceso.

#### 5.2.1.1 Determinación del árbol de cortes

La creación de la estructura del árbol de cortes se realiza aplicando técnicas numéricas de *clustering* (*clustering* aglomerativo monotético usando el *average linkage method*). Las técnicas de *clustering* analizan la afinidad entre actividades evaluando la distancia existente entre ellas y agrupándolas en función de dicha distancia. La agrupación de los departamentos refleja únicamente los requerimientos de proximidad entre las actividades en función del tráfico de materiales entre ellos. Es decir la agrupación se realiza bajo un único criterio.

En este caso la distancia será una función inversa de la intensidad relacional, es decir, la distancia será menor cuanto mayor sea la intensidad relacional. Tam propone como medida de la distancia entre dos actividades *i* y *j*:

$$d_{ij} = \frac{1}{1 + w_{ij} + w_{ji}}$$

donde  $w_{ij}$  y  $w_{ji}$  es el flujo de materiales entre las actividades. Con estas distancias es posible formar un *matriz de distancias D*, que representa la distancia existente entre cada par de actividades.

Una vez establecidas las distancias se procede al agrupamiento. Se agrupan inicialmente las dos actividades más cercanas entre sí. Tras el ello el grupo formado pasa a ser considerado como una actividad, recalculándose su distancia a cada una de las actividades restantes y modificando en consecuencia la matriz de distancias. El procedimiento continúa agrupando de nuevo aquellas actividades/grupos más cercanos entre sí.

Para un problema de *n* actividades, deberá realizarse *n-1* agrupamientos. El recálculo de las distancias debe realizarse cada vez que se crea un grupo. Para calcular la distancia a un grupo de actividades Tam emplea el *group average* como medida de la distancia entre cualquier actividad no agrupada, *a* y un grupo, *g* formado por la unión de dos elementos *i* y *j* que pueden ser actividades o *clusters* ya formados. La nueva distancia se calcula como:

$$d_{a(ij)}^2 = \frac{n_i}{n_i + n_j} d_{ai}^2 + \frac{n_j}{n_i + n_j} d_{aj}^2$$

donde:

$n_i$  es el número de actividades que conforman el grupo *i*;

$n_j$  es el número de actividades que conforman el grupo  $j$ ;

$d_{ai}$  es la distancia entre la actividad  $a$  y la actividad o grupo de actividades  $i$  antes de la fusión y

$d_{aj}$  es la distancia entre la actividad  $a$  y la actividad o grupo de actividades  $j$  antes de la fusión.

El árbol de cortes así determinado posee información sobre la agrupación de las actividades, y es posible, estableciendo el tipo de corte a realizar en cada nodo, obtener diferentes distribuciones de las actividades en la planta (Figura 5.1).

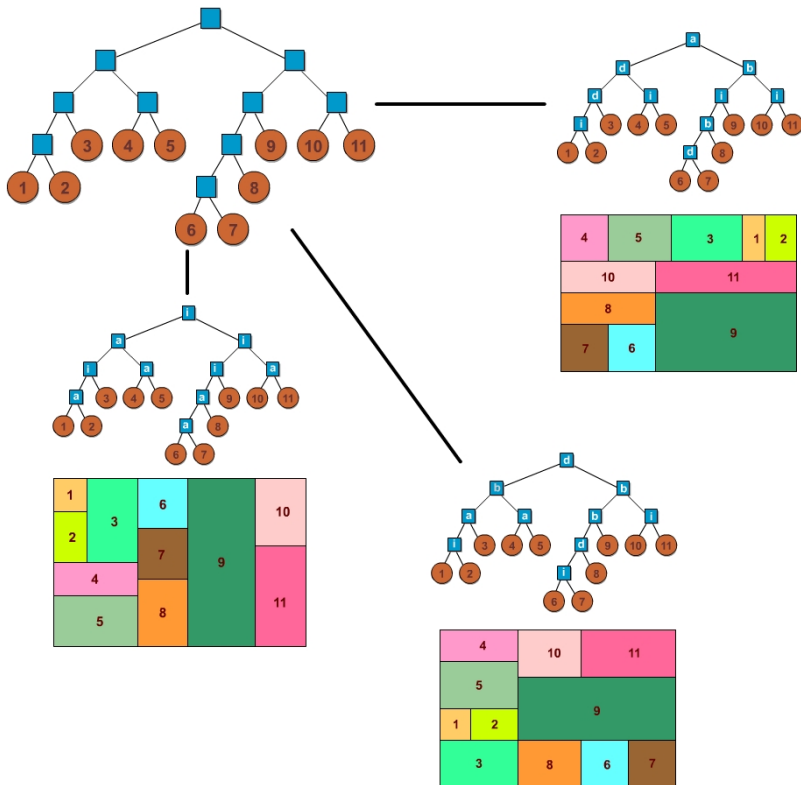


Figura 5.1: Obtención de diferentes distribuciones a partir de un árbol de cortes mediante la modificación de los operadores de corte.

Cada nodo interno del árbol representa la forma en la que se realiza el corte. El operador *arriba* divide el subdominio correspondiente mediante un corte horizontal, situando las actividades que penden de la rama izquierda del nodo en cuestión en la parte superior del corte, y las que penden de la rama derecha en la parte inferior del corte. El operador *abajo* actúa mediante un corte horizontal, situando esta vez las actividades que penden de la rama izquierda del nodo en la parte inferior del corte, y las que penden de la rama derecha en la parte superior. *Izquierda* y *derecha* aplican cortes verticales, el primero sitúa las actividades del ramal izquierdo en la parte izquierda del corte y a la derecha los del ramal derecho, mientras que el operador *derecha* actúa a la inversa. La forma de operar queda resumida en la Figura 5.2. Los operadores de corte se codifican mediante letras del alfabeto para

colocarlas en los nodos. Se emplea el código:

**u:** up; **b:** bottom; **l:** left; **r:** right




Figura 5.2: Operadores de corte en [Tam, 92c].

### 5.2.1.2 Determinación de la distribución óptima

Para poder aplicar un algoritmo genético en la búsqueda de soluciones al problema es necesario codificar las distribuciones mediante cadenas de longitud finita. Para codificar un individuo una vez establecidos los tipos de cortes de cada nodo, Tam realiza un recorrido preorden del árbol de cortes (comenzando por el nodo raíz y visitando primero la rama izquierda de cada nodo). En la Figura 5.3 se comienza por la flecha de color rojo, introduciendo los alelos que ocupan cada uno de los nodos recorridos en la cadena cromosómica. Evidentemente la codificación presupone la constancia del árbol de cortes.




Figura 5.3: Codificación de las distribuciones de un árbol de cortes en [Tam, 92c].

Se presupone, además, que tanto la forma de las actividades a distribuir como la de la planta industrial son rectangulares. Cada una de las actividades necesita para su normal desarrollo un espacio de tamaño fijo, cuya forma debe poseer un ratio alto-ancho dentro de un intervalo fijado. Este ratio estará determinado por el tipo de trabajo a realizar, los requerimientos de la maquinaria a situar en su interior, las instalaciones, los operarios...

Además de por su tamaño y su ratio alto-ancho, las superficies a ocupar por las actividades se caracterizan por su orientación, pudiendo ser ésta libre o fija. Se dice que una actividad es **libre** cuando, medido sobre un sistema de referencia dado, puede orientarse vertical u horizontalmente sin que su normal desarrollo se vea afectado. Si la orientación debe ser una concreta, bien horizontal, bien vertical, la actividad es **fija** (Figura 5.4).

El algoritmo genético planteado por Tam, tratará de localizar una distribución de las actividades que pueda ser generada por el árbol de cortes localizado en la primera fase, que minimice el coste asociado al flujo de materiales entre actividades, respetando, simultáneamente, las restricciones geométricas impuestas a las mismas. Matemáticamente el objetivo puede plantearse como:




Figura 5.4: Orientación de actividades: libre y fija.

$$\text{Min } F = \sum_{i=1}^n \sum_{j=1}^n w_{ij} d_{ij}$$

restringido a que:

$$r_i^{\min} \leq r_i \leq r_i^{\max}, i = 1 \dots n$$

donde:

- $w_{ij}$  es el coste por unidad de distancia asociado al movimiento de materiales entre las actividades  $i$  y  $j$ .
- $d_{ij}$  es la distancia rectilínea entre los centros de gravedad de las actividades  $i$  y  $j$  una vez asignadas a sus espacios.
- $r_i$ : es el ratio alto-ancho del espacio asignado a la actividad  $i$ .
- $r_i^{\max}$ : es el valor máximo permitido para la actividad  $i$  del ratio alto-ancho en una orientación predominantemente vertical.
- $r_i^{\min}$ : es el valor mínimo permitido para la actividad  $i$  del ratio alto-ancho en una orientación predominantemente vertical.

Si la actividad es libre se considera que:

$$r_i^{\min} = \min \left\{ r_i^{\min}, \frac{1}{r_i^{\max}} \right\}; \quad r_i^{\max} = \max \left\{ r_i^{\max}, \frac{1}{r_i^{\min}} \right\}$$



del mismo respecto al resto de la población. La adaptación de un individuo  $x$  de una población  $g$  cuyo genotipo es  $f$ , se define como:

$$\mu(f) = \cos te_{\max} - \cos te(x)$$

con:

- $\mu(f)$  es la adaptación al medio del individuo  $s$  (expresado en el fenotipo  $f$ ).
- $\cos te_{\max}$  es el coste del individuo peor adaptado de la población, es decir, el de mayor coste.
- $\cos te(x)$  es el coste de la solución  $x$  medido mediante la función evaluadora antes definida.

La probabilidad de selección del individuo  $s$  será:

$$P(x, g) = \frac{\mu(f)}{\sum_{\forall f} \mu(f)}$$

Una vez conocidas las probabilidades de cada individuo, estos se ordenan de mayor a menor probabilidad. Una vez ordenados se calculan las probabilidades acumuladas de cada uno, como la suma de la probabilidad propia y la de todos los que le preceden en esa ordenación.

$$P_{\text{acum}}(x_i) = \sum_{j=1}^i P(x_j)$$

De esta manera se obtienen una serie de intervalos consecutivos, comprendidos entre 0 y 1, cuyo tamaño es proporcional a la aptitud de cada individuo. Para seleccionar un individuo se genera un número aleatorio entre 0 y 1 (en la analogía se hace girar la ruleta) y se selecciona al individuo cuyo intervalo contiene dicho número aleatorio.

El cruzamiento es monopunto y se realiza eligiendo aleatoriamente el punto de cruce. Se intercambia el código genético de los progenitores que queda a ambos lados del punto de cruce (Figura 5.7).

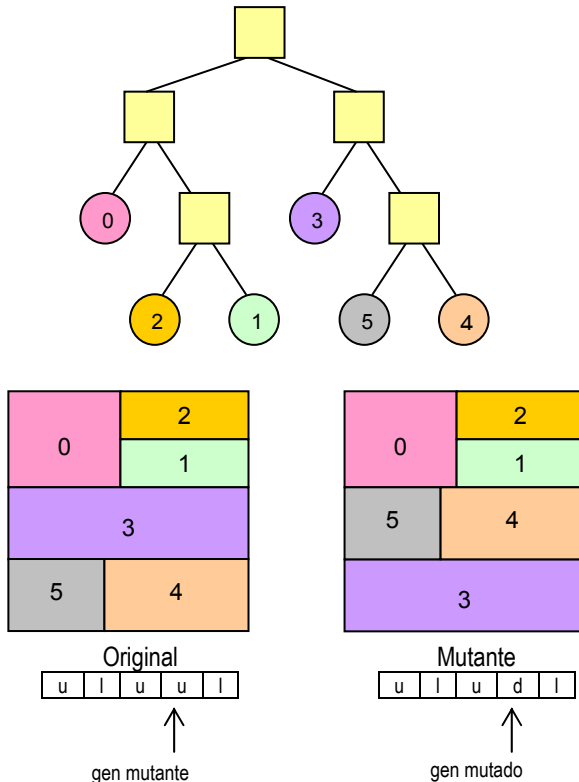


Figura 5.6: Mutación en [Tam, 92c].

La mutación selecciona aleatoriamente un gen de la cadena de un individuo, cambiando, también aleatoriamente, el alelo de dicho gen (Figura 5.6).

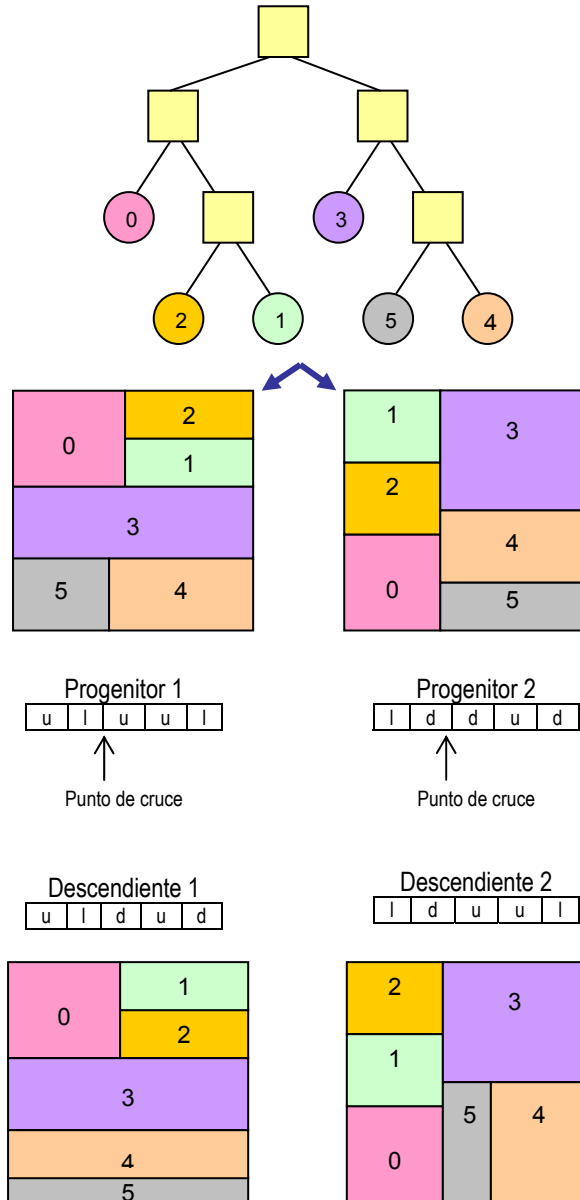


Figura 5.7: Cruce en [Tam, 92c].



## 5.2.2 La segunda propuesta de Tam: integración del árbol de cortes en el proceso evolutivo

El proceso de búsqueda de la distribución óptima para un problema dado está fuertemente condicionado por el árbol de cortes empleado. En el método que se ha expuesto se trabaja con un único árbol de cortes, lo cual excluye de la búsqueda gran parte del espacio de soluciones. Este procedimiento inicial de Tam [Tam, 92b] fue modificado por él mismo en [Tam et al., 98].

La variación fundamental de esta segunda propuesta respecto de la primera, es la introducción de una codificación de los individuos que permite la búsqueda en todo el espacio de soluciones. Para ello, el árbol de cortes y la distribución que genera se codifican mediante una representación preorden en tres partes. La primera parte de la codificación representa la estructura del árbol, la segunda el tipo de corte realizado en los nodos internos y, la tercera, las actividades que ocupan las hojas del árbol. Es esta codificación, de carácter binario, la que será sometida a los operadores genéticos correspondientes. Así la optimización podrá llevarse a cabo mediante el cambio de la estructura del árbol, el cambio del tipo de corte en cada nodo y el cambio de las actividades que ocupan cada nodo.

La codificación de la estructura del árbol emplea una cadena binaria en la que un 0 representa un nodo interno y un 1 representa una hoja del árbol. La representación, que se realiza recorriendo el árbol de manera preorden, poseerá siempre las siguientes características:

- el primer elemento de la codificación debe ser un 0 (el correspondiente al nodo raíz) y los dos últimos 1's;
- el número total de 0's debe ser igual al número de actividades menos 1, y el de 1's igual al número de actividades;
- el número de 0's existente delante de cualquier posición de la cadena debe ser mayor o igual que el de 1's.

Así pues, no es necesario representar completamente la cadena puesto que determinados elementos de la misma pueden deducirse de los restantes.

La codificación de los nodos internos se lleva a cabo definiendo el tipo de corte que se llevará a cabo en cada nodo. Un 0 indica un corte vertical y un 1 un corte horizontal. Si el corte es horizontal, las actividades que penden de la rama izquierda del nodo serán colocadas en la parte izquierda del corte, y en la derecha las restantes. Si el corte es vertical, las actividades que penden de la rama izquierda del nodo serán colocadas en la parte superior del corte, y en la inferior las restantes.

Por último, la codificación de las actividades que ocupan cada hoja del árbol se lleva a cabo realizando permutaciones de la posición de las actividades en las hojas, y almacenando en la estructura la secuencia de dichas permutaciones de forma binaria. Un ejemplo de dicha codificación es mostrada en la Figura 5.8.

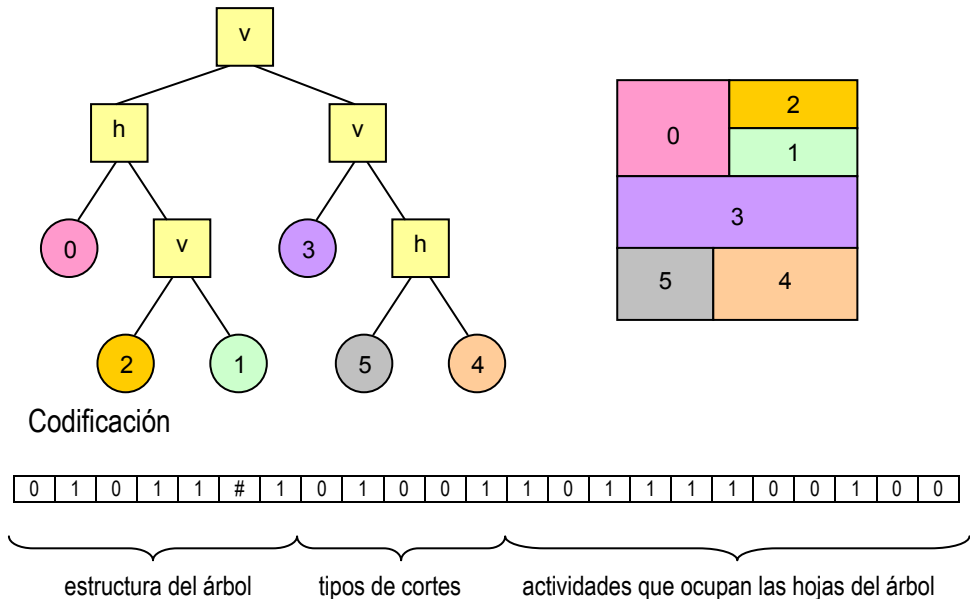


Figura 5.8: Codificación de un individuo propuesta por Tam (adaptado de [Tam et al., 98]).

Así pues, se abandona el método bifásico determinista inicial, y se adopta otro que permite una exploración irrestricta del espacio de soluciones, a costa siempre de una menor minuciosidad en la búsqueda. Por otra parte, la estructura del árbol de cortes está imbuida en la codificación de los individuos junto con la distribución a la que da lugar, por lo que su calidad es evaluada a partir de la calidad de dicha distribución. Esto provoca que un árbol prometedor pueda ser evaluado como poco apto, si la distribución que se codifica junto a él no es adecuada.

Otra modificación de menos envergadura introducida en este segundo método, es la manera de medir el incumplimiento geométrico de las actividades. Como indica Santamarina [Santamarina, 95], los incumplimientos geométricos son sesgados; las actividades dispuestas verticalmente son penalizadas en mayor medida que las horizontales, a pesar de poseer orientación libre. Con la modificación introducida se evita ese sesgo:

$$li = \max \left\{ 0, \left[ \left( r_i - r_i^{\max} \right) \left( r_i^{\min} - r_i \right) \left( r_i - \frac{1}{r_i^{\min}} \right), \left( \frac{1}{r_i^{\max}} - r_i \right) \right] \right\}$$

### 5.3. El método LAYAGEN de Santamarina

#### 5.3.1 Introducción

En 1995 Santamarina propone un método (LAYAGEN) para la resolución del problema de la distribución en planta, mediante la aplicación de algoritmos genéticos en dos fases [Santamarina, 95]. En la primera etapa se emplean los algoritmos genéticos en la localización del árbol de cortes con mayor potencialidad para generar distribuciones óptimas; en la segunda etapa se trata de localizar mediante el mismo tipo de algoritmo, la mejor distribución que es capaz de generar dicho árbol de cortes.

Podría decirse que Santamarina retorna a la estructura inicialmente propuesta por Tam, en la que la solución se busca sobre un único árbol previamente determinado y que no es modificado durante la búsqueda. La diferencia radica en la forma en la que dicho árbol es localizado: en este caso mediante un algoritmo genético cuya función evaluadora tiene carácter multicriterio. Dicha función evaluadora es una de las grandes aportaciones del método, puesto que es capaz de evaluar los árboles en función de su capacidad para generar distribuciones que constituyan buenas soluciones al problema desde un punto de vista multicriterio, cuestión que a priori no parece sencilla.

El método de Santamarina trata de resolver algunas de las deficiencias del método propuesto por Tam <sup>36</sup>, que según indica la propia autora son:

- que la construcción del árbol de cortes se realiza en base a un único criterio, el coste derivado del transporte de materiales entre actividades, respondiendo únicamente al principio de mínima distancia,
- que el procedimiento de *clustering* emplea distancias entre clusters del tipo *group average* para lograr árboles de corte lo más equilibrados posibles, cuando en ocasiones, la necesidad de separación entre determinadas actividades puede hacer recomendable el empleo de árboles desequilibrados que permitan el alejamiento de dichas actividades en la distribución final,
- que el empleo de un único árbol de cortes de estructura equilibrada limita la búsqueda a una zona concreta del espacio de soluciones y
- que la geometría del dominio de ubicación debe ser conocida a priori, planteamiento que no es óptimo para el caso de construcción de una planta completamente nueva, dado que limita el estudio de los posibles fenotipos de las soluciones contenidas en el árbol de cortes al fijar un único dominio de ubicación.

Según Santamarina, estas razones justifican la necesidad del estudio de la estructura del árbol de cortes como paso previo a la búsqueda de las soluciones que dicho árbol es capaz de generar. La autora plantea una analogía con la naturaleza según la cuál, cada árbol de cortes representa una especie y cada solución contenida en un árbol es un individuo de dicha especie. Es aconsejable, en la búsqueda del individuo más adaptado a un entorno,

---

<sup>36</sup> El trabajo de Santamarina se presentó en 1995, antes de la publicación de la segunda propuesta de Tam en 1998 [Tam et al., 98], en la que el árbol de cortes es codificado e incluido en las cadenas del algoritmo. Así pues, Santamarina propone mejorar el método que Tam presentó en 1992 [Tam, 92c].

seleccionar primero la especie con más probabilidades de éxito y, posteriormente, el individuo adecuado de dicha especie.

### 5.3.2 La primera fase: optimización del árbol de cortes

En el método LAYAGEN obtener el árbol de cortes óptimo para la distribución de  $n$  actividades supone determinar la estructura del árbol (la forma de las diferentes ramas y la posición de los nodos que indican los cortes), y la posición de las  $n$  actividades en cada una de las hojas (extremos de las ramas), con mayor capacidad para generar distribuciones que supongan buenas soluciones al problema planteado. Los diferentes individuos de esa especie, o lo que es lo mismo, las diferentes soluciones que genera dicho árbol, pueden obtenerse estableciendo el tipo de corte a realizar en cada nodo. Será en la segunda fase en la que se determinen dichos tipos de cortes.

Como se indica en [Santamarina, 95], el número de posibles árboles de corte (análogamente de especies) que es posible formar con  $n$  actividades es:

$$\frac{1}{2^{n-1}} \prod_{i=0}^{n-2} (n-i)(n-i-1)$$

Para localizar el árbol óptimo (o al menos subóptimo) para el problema planteado se plantea un algoritmo genético. Para ello es necesario establecer un sistema de codificación de los árboles de corte mediante cadenas (o cromosomas).

#### 5.3.2.1 Codificación de los árboles de corte

La aplicación de los algoritmos genéticos en la búsqueda del árbol óptimo requiere el empleo de un mecanismo de codificación/descodificación de su estructura. La codificación empleada por Santamarina es diferente a las que propuso Tam posteriormente [Tam et al., 98], no es binaria y es quizá más complejo el mecanismo de codificación/decodificación. Como contrapartida, las cadenas resultan más compactas, y la probabilidad de obtener individuos no factibles a raíz de la aplicación de los operadores genéticos es algo menor que en la codificación de Tam. La codificación es función del procedimiento empleado para la generación de los árboles de corte mediante la formación de clusters.

Supóngase el caso de  $n$  actividades numeradas desde 1 hasta  $n$ . El primer cluster se forma eligiendo aleatoriamente dos actividades, cluster al que se denominará  $n+1$ . Los números que representan las actividades seleccionadas conforman los dos primeros elementos de la cadena que representa al árbol (ver Figura 5.9).

Se repite el proceso de selección aleatoria para la formación de un nuevo cluster. Se podrán seleccionar dos elementos del conjunto formado por las actividades que no forman parte de ningún cluster y los cluster ya formados. Los dos números que representan las actividades o clusters seleccionados se añaden a la cadena representativa del árbol. Este procedimiento se repite hasta que no quede ningún elemento por seleccionar.

Las cadenas así formadas tendrán una longitud de  $2 \cdot n - 2$  elementos (genes), de los cuales  $n - 2$  son valores mayores que  $n$  y representan clusters o agrupación de elementos. Los genes pueden tomar valores en el conjunto de alelos  $\theta = \{1, 2, 3, \dots, 2 \cdot n - 2\}$ .




Figura 5.9: Generación de árboles de cortes y codificación en cadenas en LAYAGEN.

En el proceso de descodificación de las cadenas se consideran los elementos o genes que la forman por parejas (Figura 5.10). El número de parejas será  $n-2$ , tantas como agrupaciones realizadas o como nodos conformarán el árbol de cortes. El primer par de genes representan las actividades contenidas en el primer cluster (el  $n+1$ ) y que penderán de un mismo nodo, el segundo par de genes representan las actividades contenidas en el cluster ( $n+2$ ) y así sucesivamente. El primer elemento de cada par penderá a la izquierda del nodo correspondiente.

Cuando uno de los elementos de un par es mayor que  $n$ , indica que de ese nodo pende las actividades de otro par previamente formado. Si los dos elementos son mayores que  $n$ , de dicho nodo penden dos nodos ya formados con sus respectivas actividades.

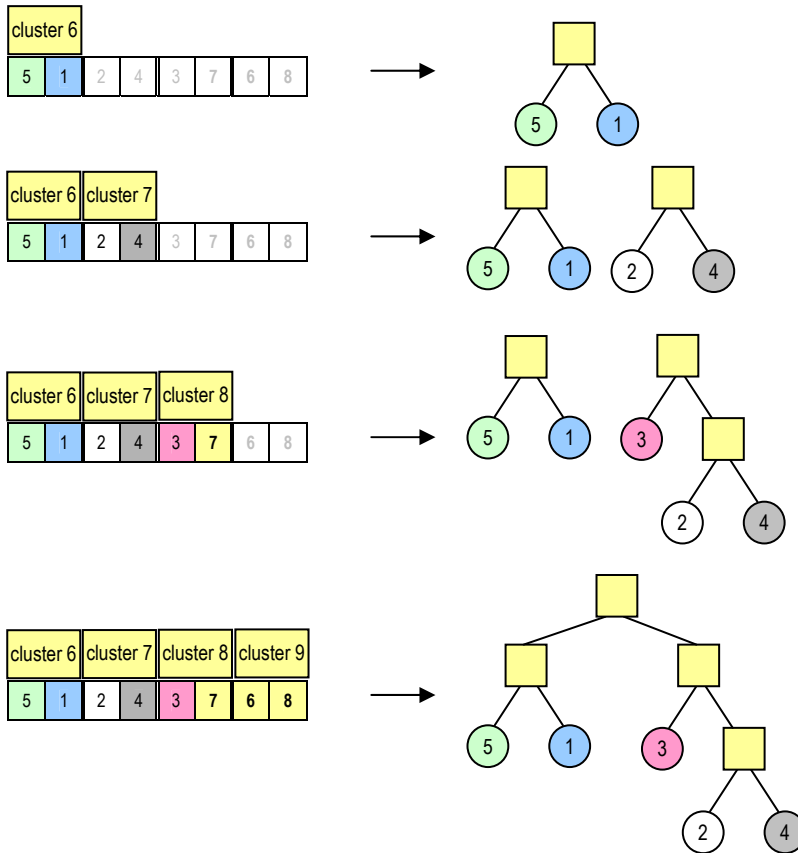


Figura 5.10: Decodificación de cromosomas en LAYAGEN para obtener los árboles de corte que representan.

El último de los clusters, el denotado como  $2 \cdot n - 1$  (cluster 9 en la figura), no aparece explícitamente en la cadena como elemento dado que proporcionaría una información innecesaria. Evidentemente el último nodo/cluster debe ser el nodo raíz.

También resulta evidente que, para que un elemento mayor que  $n$  pueda aparecer en la cadena, el cluster que representa debe haber aparecido previamente en posiciones precedentes. Concretamente, un elemento  $x > n$  no puede aparecer en la cadena en posiciones inferiores a  $2 \cdot (x - n) + 1$ , dado que esto implica que se debe colocar en el árbol de cortes un cluster que aún no ha sido formado.

### 5.3.2.2 Generación de la población inicial de árboles de corte

En el apartado anterior se ha explicado la formación de árboles de corte mediante la formación de clusters de actividades. Para generar la población inicial de árboles Santamarina procede como se indica en la Figura 5.11.

```

comienzo
n=número de actividades
m=tamaño de la población
para x=1 hasta n
  {
  cluster x= actividad x           //creación de una lista de clusters
  }
para x=1 hasta m
  {
  u=1
  para y=1 hasta n-1
    {
    selección aleatoria de dos clusters i y j de la lista
    cluster n+u = fusion(i,j)
    eliminar i y j de la lista de clusters disponibles
    añadir n+u a la lista de clusters disponibles
    u=u+1
    }
  }
fin

```

Figura 5.11: Generación de una población de  $m$  árboles de corte (especies). Adaptado de [Santamarina, 95].

De esta manera se obtiene una población de  $m$  árboles de corte generada de manera aleatoria. Obtenida ésta, y siguiendo el esquema habitual de un algoritmo genético, se hace necesario establecer la forma de medir el grado de adaptación de cada uno de los individuos de la población (en este caso especies) al medio. Se debe establecer pues, una función evaluadora de la calidad de un árbol como ente potencialmente capaz de contener la distribución de mínimo coste.

### 5.3.2.3 Estimación de la capacidad del árbol de cortes para generar distribuciones de mínimo coste relacional

Santamarina emplea el Potencial del Árbol de Cortes para localizar el árbol potencialmente capaz de contener las distribuciones de menor coste relacional. El potencial de un árbol de cortes es una medida de la capacidad de dicho árbol, para que las distribuciones generadas a partir del mismo permitan la adyacencia de aquellas actividades que así lo requieran. Santamarina plantea que la potencialidad de adyacencia de dos actividades depende del nivel en que se encuentren éstas en el árbol, más concretamente de la diferencia de profundidad de las mismas.

En el árbol de la Figura 5.12, las actividades 3 y 7 tienen pocas posibilidades de resultar adyacentes en las distribuciones generadas (sin ser imposible como puede apreciarse en el

caso b), sin embargo, actividades como la 1 y la 2 resultarán adyacentes en cualquiera de las distribuciones obtenidas a partir de dicho árbol. Por el método de construcción de la solución, las áreas para las actividades que penden del mismo nodo se formarán a partir del corte de un dominio común, siendo necesariamente adyacentes.

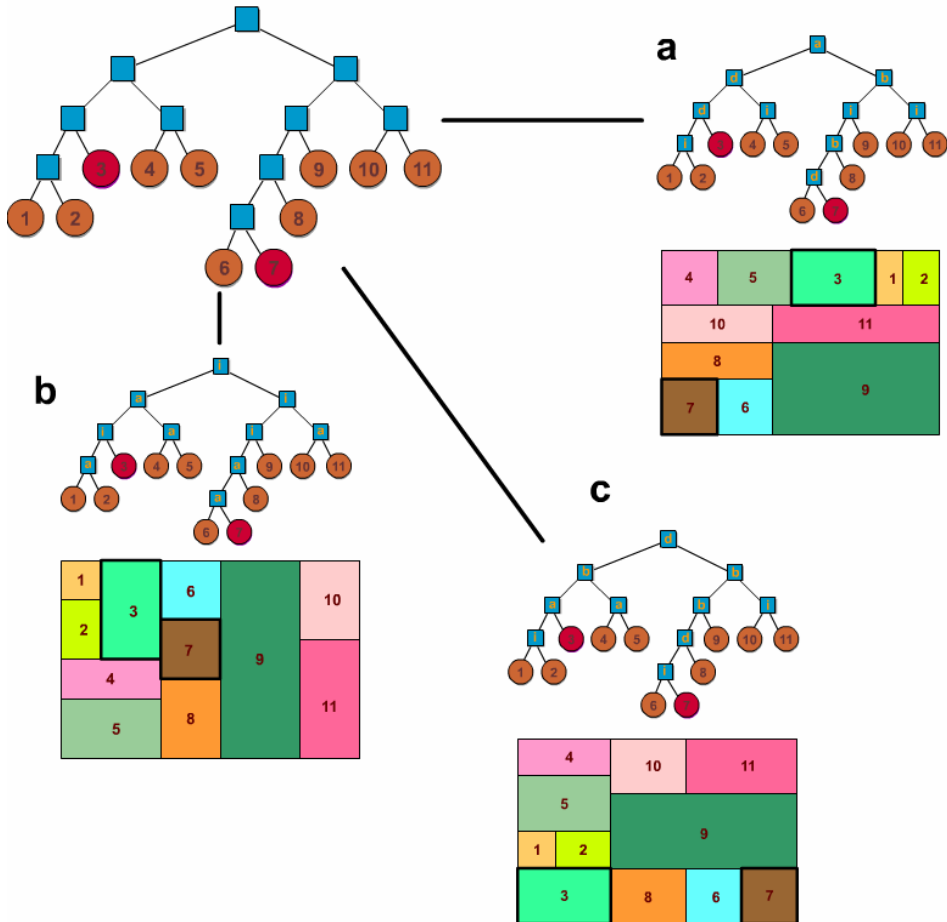


Figura 5.12 : Distintas distribuciones generadas por un árbol de cortes.

### 5.3.2.3.1 Potencial de adyacencia entre actividades de un árbol de cortes

Santamarina propone un estimador (Potencial de Adyacencia) de la capacidad de dos actividades para mantener una frontera común, dentro de las diferentes distribuciones contenidas en un árbol de cortes (con valores en el intervalo  $[0,1]$ ). Para dos actividades  $i$  y  $j$ , el estimador es función del número de nodos a recorrer de manera ascendente desde la actividad  $i$  hasta el primer nodo común con la actividad  $j$ , y del número de nodos a recorrer de manera ascendente desde la actividad  $j$  hasta el primer nodo común con la actividad  $i$  (ver Figura 5.13).



El Potencial de Adyacencia de las Actividades  $i$  y  $j$  queda definido como:

$$P(i,j) = P(i) \cdot P(j)$$

siendo a su vez:

$P(i)$  = el potencial de la actividad  $i$  respecto a la actividad  $j$

$P(j)$  = el potencial de la actividad  $j$  respecto a la actividad  $i$




Figura 5.13: Dos ejemplos del camino a recorrer de manera ascendente desde una actividad  $j$  hasta el primer nodo común con otra actividad  $i$ .

Llamando  $k$  al primer nodo común entre ambas actividades, el potencial de la actividad  $i$  respecto a la actividad  $j$  dependerá de la capacidad de  $i$  para mantener alguno de sus lados

en la periferia del subdominio que se generará tras el corte definido en el nodo  $k$ .

En la Figura 5.14 puede observarse que la actividad  $i$  mantendrá, en todos los casos, al menos dos lados exteriores al subdominio, no existiendo la posibilidad de ser una actividad con todos sus lados internos.

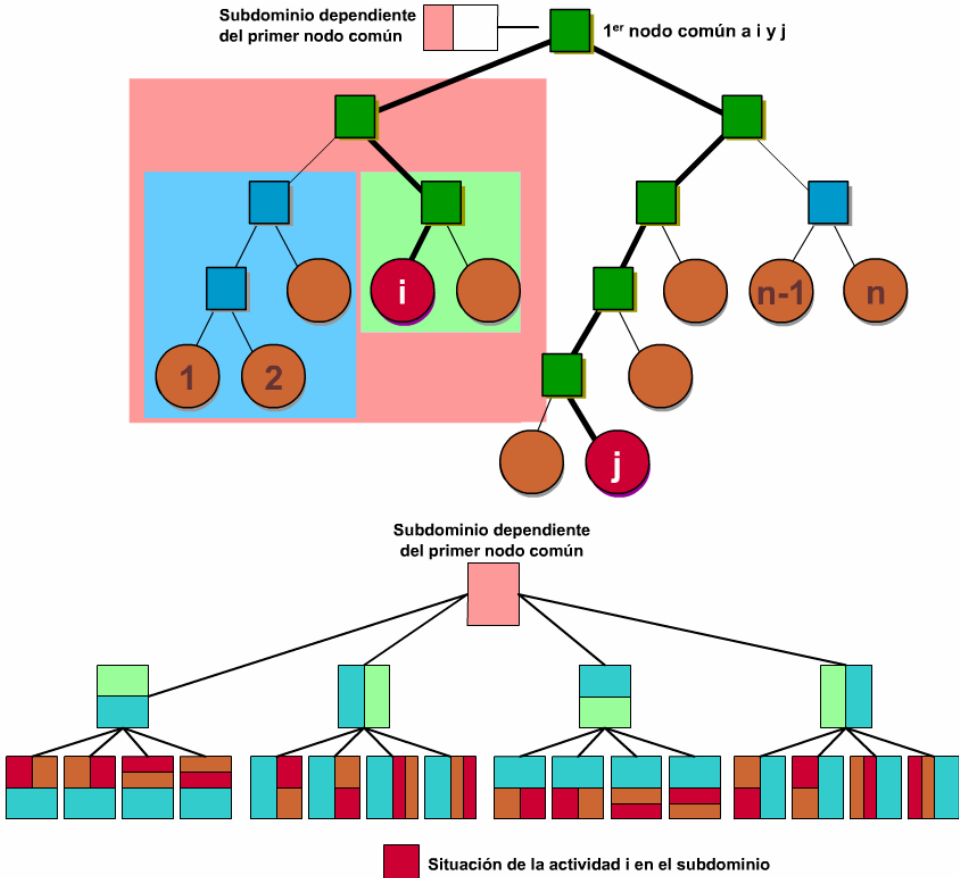


Figura 5.14 : Posibles situaciones de  $i$  en el subdominio dependiente de su nodo común con  $j$ .

Santamarina propone estimar  $P(i)$  como:

$$P(i) = \frac{4 \cdot 3^{s-1}}{4s} = \left(\frac{3}{4}\right)^{s-1}$$

donde  $s$  es el número de nodos existentes en el recorrido desde la actividad  $i$  hacia el nodo raíz, hasta encontrar el primer nodo común ( $k$ ), del mismo camino recorrido desde  $j$ .

En la fórmula anterior, el denominador  $4s$  es el número total de posibles configuraciones que puede adoptar el subdominio pendiente del nodo  $k$ , en función de los cortes que se realicen. El numerador es la suma de todos los lados que mantiene exteriores la actividad  $i$

en todas las posibles configuraciones ( $4s$ ) que puede adoptar el subdominio. La justificación de este valor puede consultarse en [Santamarina, 95].

Realizando el mismo cálculo para la actividad  $j$  se obtiene que:

$$P(j) = \frac{4 \cdot 3^{s'-1}}{4s'} = \left(\frac{3}{4}\right)^{s'-1}$$

donde  $s'$  es el número de nodos existentes en el recorrido desde la actividad  $j$  hacia el nodo raíz, hasta encontrar el primer nodo común ( $k$ ), del mismo camino recorrido desde  $i$ .

Así, el Potencial de Adyacencia de las actividades  $i$  y  $j$  queda definido de la siguiente manera:

$$P(i, j) = P(i) \cdot P(j) = \frac{4 \cdot 3^{s-1}}{4s} \cdot \frac{4 \cdot 3^{s'-1}}{4s'} = \left(\frac{3}{4}\right)^{s+s'-2}$$

De la fórmula anterior puede deducirse que en el caso de actividades que penden del mismo nodo, sea cual sea la distribución generada, forzosamente poseerán frontera común y su Potencial de Adyacencia tomará el valor de 1 ( $s=1$ ;  $s'=1$ ). Es necesario destacar que el Potencial de Adyacencia considera el número de configuraciones en las que ambas actividades tienen fronteras exteriores en sus respectivos subdominios, lo cual no implica su adyacencia real como puede apreciarse en la Figura 5.15.

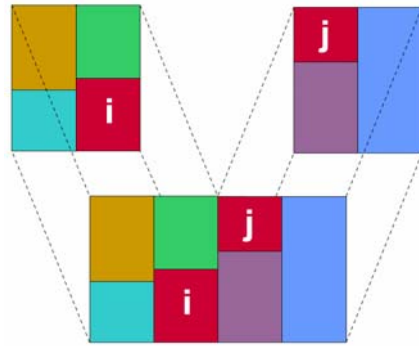


Figura 5.15: Actividades exteriores en sus subdominios y no adyacentes.

Como ejemplo, dado el árbol de cortes de la

Figura 5.16, los potenciales de adyacencia de los pares de actividades (1,2), (6,10) y (6,9) se calcularían de la siguiente manera:

$$P(1,2) = P(1)_{s=1} \cdot P(2)_{s'=1} = \left(\frac{3}{4}\right)^0 \left(\frac{3}{4}\right)^0 = 1$$

$$P(6,10) = P(6)_{s=2} \cdot P(10)_{s'=1} = \left(\frac{3}{4}\right)^1 \left(\frac{3}{4}\right)^0 = 0.75$$

$$P(6,9) = P(6)_{s=4} \cdot P(9)_{s'=1} = \left(\frac{3}{4}\right)^3 \left(\frac{3}{4}\right)^0 = 0.4219$$




Figura 5.16 : Cálculo del potencial de adyacencia entre actividades.

### 5.3.2.3.2 Potencial del árbol de cortes

Para estimar la potencialidad global del árbol de cortes a partir de los potenciales de adyacencia de cada par de actividades, Santamarina utiliza el Potencial del Árbol de Cortes, definiéndolo como:

$$P(AC) = \sum_{i=1}^n \sum_{j=1}^n P(i, j) \cdot \left[ \pm \sum_{u=1}^k \alpha_u \cdot f_{u,ij} \pm \sum_{v=1}^{k'} \beta_v \cdot t_{v,ij} \right]$$

donde:

**P(i,j)**: potencial de adyacencia de las actividades i y j del árbol de cortes.

**$\alpha_u, \beta_v$** : coeficientes de ponderación de la importancia relativa entre factores de tipo cuantitativo y cualitativos.

**$f_{u,ij}, t_{v,ij}$** : valor de la *intensidad relacional*<sup>37</sup> de las actividades i y j bajo el criterio cuantitativo u\_ésimo y bajo el criterio cualitativo v\_ésimo respectivamente.

**k, k'**: número de criterios (cuantitativos y cualitativos respectivamente) contemplados.

Ésta es pues, la función de evaluación empleada en la primera fase de LAYAGEN.

### 5.3.2.4 Los operadores genéticos

Concretada la manera de generar la población inicial y de evaluar a cada una de sus individuos, Santamarina define los tres operadores estándar de un algoritmo genético adaptados a la codificación establecida.

#### 5.3.2.4.1 Selección

Para seleccionar los individuos que sobrevivirán y los reproductores se emplea un procedimiento de ruleta clásico. El procedimiento de selección por ruleta ha sido tratado ya en el capítulo anterior y se emplea sin cambios en LAYAGEN.

A cada individuo se le asigna una probabilidad de ser elegido proporcional a su aptitud para sobrevivir en el medio. La selección se lleva a cabo de manera aleatoria dirigida, de forma que los individuos más adaptados tengan más probabilidad de sobrevivir, pero proporcionando alguna esperanza de supervivencia y reproducción a los menos dotados.

#### 5.3.2.4.2 Cruce

El cruzamiento de dos árboles de corte (especies), dada la codificación establecida, resulta un tanto más complicado que en el caso de emplear un alfabeto binario, con una

---

<sup>37</sup> Santamarina emplea la intensidad relacional como se define en [Hospitaller et al., 86] :

$$w_{ij} = f_{ij} + \alpha \cdot tra_{ij}$$

siendo:

$f_{ij}$  la carga de transporte entre las actividades i y j

$tra_{ij}$  la necesidad de proximidad entre las actividades i y j estimada mediante la tabla relacional de actividades

$\alpha$  coeficiente que pondera la importancia relativa de ambos criterios

elevada probabilidad de dar lugar a especies no factibles si se emplea el procedimiento más habitual, el cruce monopunto.

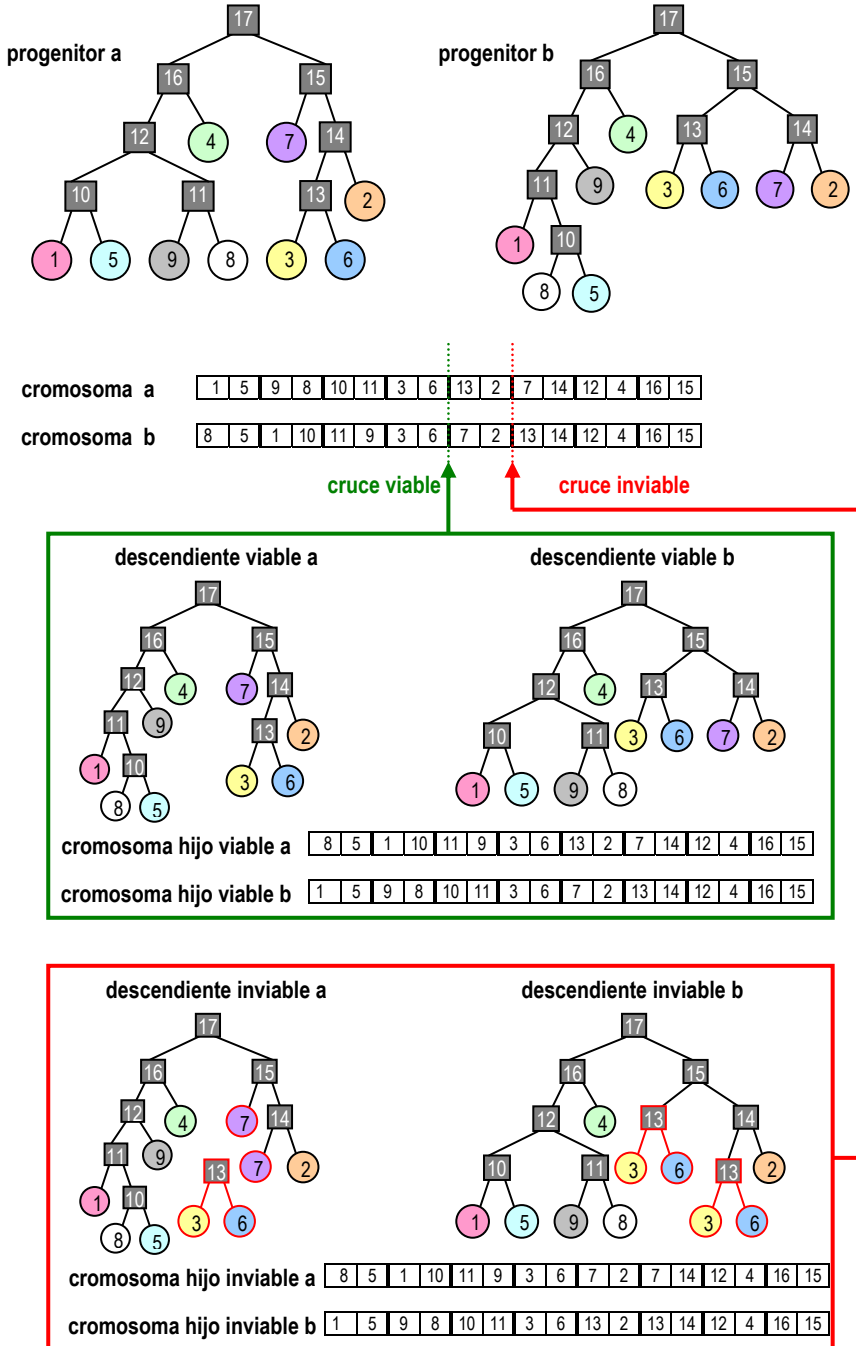


Figura 5.17: Cruce de dos especies en LAYAGEN para obtener híbridos interespecíficos. Casos de descendencia viable e inviable.

En la Figura 5.17 puede observarse (remarcado en color verde) el caso de un cruce exitoso en el que la descendencia son dos árboles de corte viables. El cruce realizado es monopunto, intercambiándose las subcadenas que quedan a cada lado del punto de cruce escogido. Las dos cadenas obtenidas pueden interpretarse (y así lo hace Santamarina), como cromosomas que representan las características fundamentales de especies híbridas interespecíficas, resultado del cruce de las dos especies progenitoras.

Remarcado en color rojo se observa el resultado de un cruce que produce descendencia inviable. Las cadenas resultantes contienen errores que pueden ser de diversos tipos: actividades o clusters repetidos, actividades o clusters inexistentes o que un determinado cluster aparezca en la cadena antes de haber sido formado. El primero de los descendientes inviables de la Figura 5.17 posee repetida la actividad 7, mientras que el cluster 13, que contiene a las actividades 3 y 6, no está contenido en ningún cluster de nivel superior, es decir, el alelo 7 aparece dos veces en la cadena mientras que el 13 no aparece. En la segunda cadena descendiente la actividad 7 no aparece, mientras que el cluster 13 está duplicado. Esto provoca que en la decodificación se dupliquen las actividades contenidas en el cluster 13 (la 3 y la 6) y que la actividad 7 no aparezca.

Así pues, el cruce empleado en la primera fase de LAYAGEN no es un operador cerrado pudiendo dar lugar especies híbridas inviables. Como precisa Santamarina, a semejanza de cómo ocurre en la naturaleza, dos especies tienen mayor probabilidad de cruzarse con éxito conforme más similares sean sus códigos genéticos. Santamarina no establece ningún mecanismo de reparación de cadenas que representen árboles no viables.

### 5.3.2.4.3 Mutación

El operador mutación actúa intercambiando el valor de los alelos de dos genes escogidos de manera aleatoria. La forma tradicional de mutación (cambiando el valor del alelo de un gen), resulta inviable en este caso dado que siempre daría lugar a individuos infértiles. En caso de emplear este sistema se incumpliría la condición de que una actividad o cluster no puede estar repetida en la cadena para representar un árbol viable.

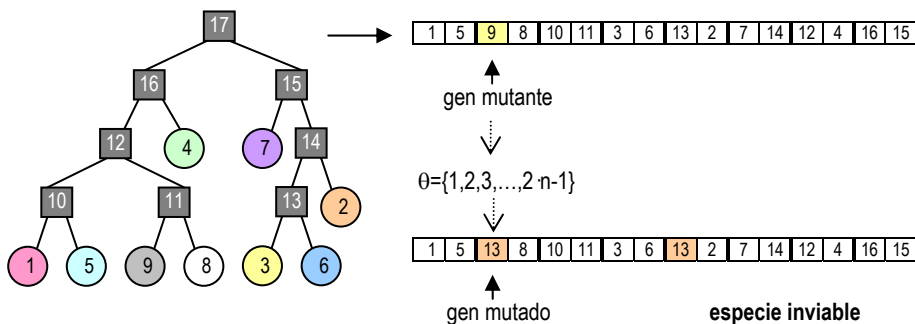


Figura 5.18: Inviabilidad de la aplicación de la mutación clásica en la primera fase de LAYAGEN.

En la Figura 5.18 se ejemplifica la mutación mediante el cambio del alelo de un gen. El tercer gen es mutado cambiando su alelo. Como debe escogerse alguno del conjunto  $\theta$ , y el cardinal de dicho conjunto es igual al número de genes, necesariamente resulta una cadena en la que una actividad o cluster está duplicado (el 13 en la figura) y uno falta (el 9).

Para evitar esto, se define el operador mutación como el intercambio de los alelos de dos genes escogidos aleatoriamente. Esto de por sí no garantiza que la estructura resultante sea viable, pues puede ocurrir que el intercambio de alelos provoque la aparición en la cadena de un cluster todavía no formado. En la Figura 5.19, puede apreciarse que al intercambiar los alelos de los genes tercero y noveno de la cadena representada, el alelo 13 se sitúa en el cromosoma en una posición anterior a la formación de dicho cluster, lo cual provoca la inviabilidad del árbol representado.

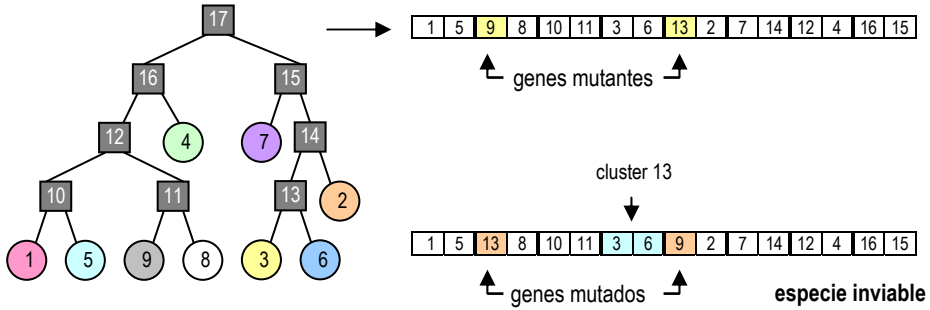


Figura 5.19: Mutación en la primera fase de LAYAGEN: obtención de un árbol inviable.

En la Figura 5.20 se representa una operación de mutación que da como resultado un árbol viable. La comprobación a realizar para asegurar la viabilidad es que ningún cluster puede estar formado por elementos de mayor o igual orden que el cluster en cuestión.

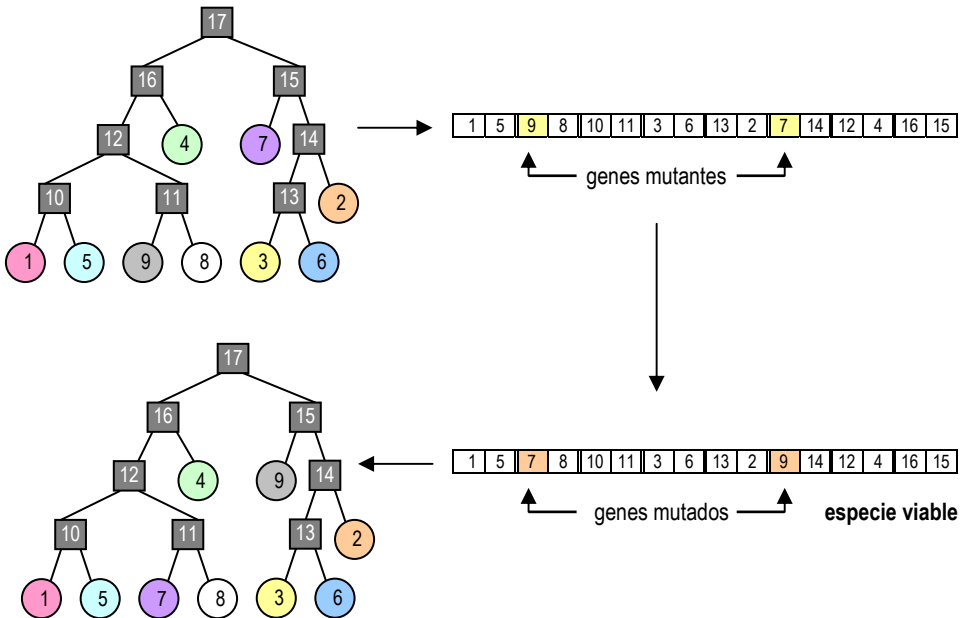


Figura 5.20: Mutación en la primera fase de LAYAGEN: obtención de un árbol viable.

### 5.3.3 La segunda fase: optimización de las distribuciones contenidas en el árbol de cortes

La primera fase del método LAYAGEN permite la obtención del árbol de cortes óptimo para la distribución de  $n$  actividades. Esto supone determinar la estructura del árbol y la posición de las  $n$  actividades en cada una de las hojas, con mayor capacidad para generar distribuciones que supongan buenas soluciones al problema planteado. Una vez determinado dicho árbol, los diferentes individuos de esa especie, o lo que es lo mismo, las diferentes soluciones que es capaz de generar, pueden obtenerse estableciendo el tipo de corte a realizar en cada nodo. Será en esta segunda fase en la que se determinen dichos tipos de cortes mediante el empleo de un segundo algoritmo genético.

El método LAYAGEN añade una variable más a optimizar además del tipo de cada uno de los cortes. Como se indica en 5.3.1, Santamarina considera que la geometría del dominio de ubicación de la planta no tiene porqué estar fijada a priori como ocurriría en el caso de un edificio de nueva construcción. En estos casos, puede resultar conveniente la adaptación del edificio al proceso, tratando de localizar la geometría del dominio que resulte más eficiente. Así pues, la segunda fase de LAYAGEN trata de localizar, además de los tipos cortes convenientes, el ratio alto-ancho de la planta más adecuado.

A este respecto se establece la analogía siguiente: la variabilidad subyacente en los individuos de una especie no es consecuencia únicamente del genotipo del sujeto (en este caso lo será también de los tipos de cortes que lo genera), dado que el entorno en que se desenvuelve influye en el fenotipo que finalmente expresa. En este sentido, en la Figura 5.21 se aprecia como la forma del dominio de ubicación sería análoga el entorno que condiciona cómo el genotipo (los tipos de cortes) se expresa en un fenotipo determinado (distribución).

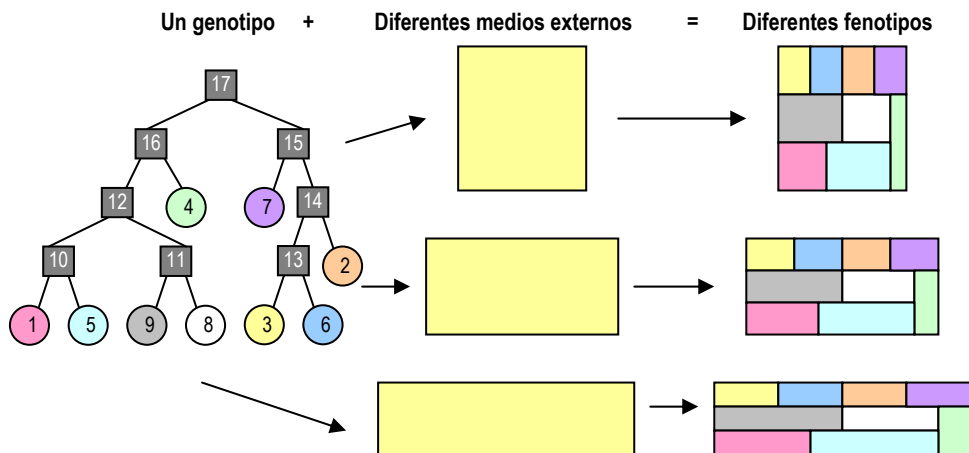


Figura 5.21: Analogía entre la segunda fase de LAYAGEN y la influencia del medio externo en la expresión fenotípica.



### 5.3.3.1 Codificación de las soluciones y generación de la población inicial

Los cromosomas que representan a los individuos en la segunda fase de LAYAGEN, son cadenas de genes cuyos alelos indican el tipo de corte a realizar en cada nodo del árbol de cortes obtenido en la primera fase.

Santamarina establece los mismos cuatro posibles tipos de corte que Tam, llamando en este caso “a” al corte horizontal que coloca la primera actividad implicada en el subdominio superior obtenido, “b” al corte horizontal que coloca la primera actividad implicada en el subdominio inferior de los obtenidos, “i” al corte vertical que establece la primera actividad implicada en el subdominio izquierdo obtenido, y “d” al corte vertical que coloca la primera actividad implicada en el subdominio superior obtenido. Dado que el método establece cuatro posibles formas de realizar el corte indicado por cada nodo, el número de posibles soluciones a un problema dado será como máximo <sup>38,39</sup>:

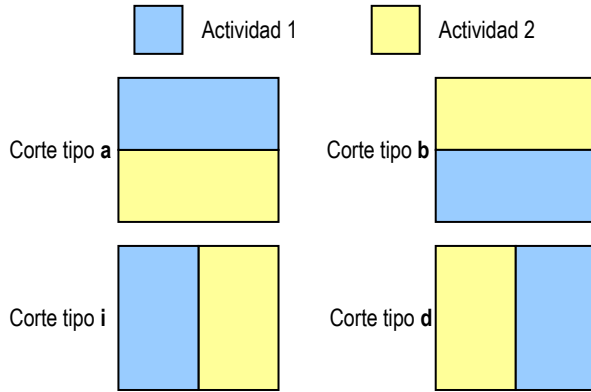


Figura 5.22: Tipos de corte en el método LAYAGEN.

$$2^{n-1} \prod_{i=0}^{n-2} (n-i)(n-i-1)$$

Para codificar un individuo una vez establecidos los tipos de cortes de cada nodo, Santamarina emplea el mismo procedimiento que Tam. Realiza un recorrido preorden del árbol de cortes (comenzando por el nodo raíz y visitando primero la rama izquierda de cada nodo).

Ya se ha expuesto que Santamarina introduce la forma de la planta donde se ubicarán las actividades como variable del problema. Sin pérdida de generalidad supone el dominio rectangular y añade la información del ratio alto-ancho de la planta en el último gen del cromosoma (Figura 5.23). El alelo correspondiente puede tomar valores en el intervalo comprendido entre los ratios máximos y mínimos permitidos ( $[r_{\min}, r_{\max}]$ ). Así pues, una distribución de  $n$  actividades queda representada por una cadena de  $n$  genes.

<sup>38</sup> Dos árboles de corte diferentes pueden generar en determinadas condiciones una misma distribución, por lo que lo que se ofrece es una cota superior del número de posibles soluciones.

<sup>39</sup> En el caso de que el dominio de ubicación no tenga una geometría fijada a priori, y ésta sea una variable del problema, el número de posibles soluciones aumenta. En realidad, si las dimensiones del dominio pueden tomar cualquier valor dentro de un intervalo, el número de soluciones es infinito.




Figura 5.23: Codificación de las distribuciones de un árbol de cortes en LAYAGEN.

La generación de la población inicial de individuos se realiza de manera aleatoria, es decir, se generan los cromosomas introduciendo de manera aleatoria los alelos en cada cadena. Dado el sistema de codificación empleado, la única precaución a adoptar para lograr individuos factibles es que el valor del último gen esté comprendido en el intervalo de ratios permitido de la planta.

### 5.3.3.2 Medición de la aptitud de los individuos

Para medir la aptitud de los individuos LAYAGEN emplea una función multiobjetivo basada en el coste relacional de la distribución, enunciada como sigue:

$$CR = \sum_{i=1}^n \sum_{j=1}^n d_{ij} \left[ \pm \sum_{u=1}^k \alpha_u \cdot f_{u,ij} \pm \sum_{v=1}^{k'} \beta_v \cdot t_{v,ij} \right] + \mu \sum_{i=1}^n (l_i + 1)^p$$

con:

$f_{u,ij}$ ,  $t_{v,ij}$ : valor de la *intensidad relacional*<sup>40</sup> de las actividades  $i$  y  $j$  bajo el criterio cuantitativo  $u$ -ésimo y bajo el criterio cualitativo  $v$ -ésimo respectivamente.

$\alpha_u$ ,  $\beta_v$ ,  $\mu$ : coeficientes de ponderación de la importancia relativa entre factores de índole cuantitativa y cualitativa y geométrica.

$f(l_i)$ : penalización del incumplimiento de las restricciones geométricas de la actividad  $i$ .

$k$ ,  $k'$ : número de criterios (cuantitativos y cualitativos respectivamente) contemplados.

$d_{ij}$ : distancia<sup>41</sup> entre los centros de gravedad de las actividades  $i$  y  $j$ .

$p$ : parámetro que toma valores entre 1 e infinito que pretende aumentar de forma potencial la

<sup>40</sup> Santamarina emplea la intensidad relacional como se define en [Hospitaller et al., 86] :

$$w_{ij} = f_{ij} + \alpha \cdot tra_{ij}$$

siendo:

$f_{ij}$  la carga de transporte entre las actividades  $i$  y  $j$

$tra_{ij}$  la necesidad de proximidad entre las actividades  $i$  y  $j$  estimada mediante la tabla relacional de actividades

$\alpha$  coeficiente que pondera la importancia relativa de ambos criterios

<sup>41</sup> Santamarina emplea en LAYAGEN la distancia rectilínea, pero puede emplearse indistintamente cualquier otra.

penalización cuando aumenta el incumplimiento.

Las restricciones geométricas de los espacios a los que son asignadas las actividades son definidos mediante ratios alto-ancho mínimos y máximos permitidos, y su incumplimiento en una distribución dada ( $l_i$ ), se mide de la manera siguiente si las actividades de orientación libre:

$$l_i = \max \left\{ 0, \frac{\max \{ \text{alto}_i, \text{ancho}_j \}}{\min \{ \text{alto}_i, \text{ancho}_j \}} - \max \left\{ r_i^{\max}, \frac{1}{r_i^{\min}} \right\} \right\}$$

donde:

$r_i^{\max}$ : es el valor máximo permitido para la actividad  $i$  del ratio alto-ancho en una orientación predominantemente vertical.

$r_i^{\min}$ : es el valor mínimo permitido para la actividad  $i$  del ratio alto-ancho en una orientación predominantemente vertical.

**alto**: alto de la actividad  $i$ .

**ancho**: ancho de la actividad  $i$ .

Si las actividades son de orientación fija se distingue entre las verticales y las horizontales, empleando las ecuaciones:

$$\begin{aligned} l_i &= r_i - r_i^{\max} && ; \text{ si } r_i > r_i^{\max} && ; \\ l_i &= 1/r_i - 1/r_i^{\min} && ; \text{ si } r_i < r_i^{\min} \text{ y } r_i < 1 && ; \\ l_i &= r_i^{\min} - r_i && ; \text{ si } r_i < r_i^{\min} \text{ y } r_i \geq 1 && ; \end{aligned}$$

en caso de orientación fija vertical, y aplicando a éstas mismas ecuaciones las transformaciones:

$$\begin{aligned} 1/r_i^{\min} &= r_i^{\max} ; \\ 1/r_i^{\max} &= r_i^{\min} ; \\ 1/r_i &= r_i ; \end{aligned}$$

para el caso de actividades de orientación fija horizontal.

Esta forma de medir los incumplimientos trata de evitar el sesgo introducido por la propuesta en [Tam, 92c]<sup>42</sup>; en ésta, las actividades dispuestas verticalmente son penalizadas en mayor medida que las horizontales, a pesar de poseer orientación libre.

### 5.3.3.3 Operadores genéticos

El operador selección actúa de la misma forma que el empleado en [Tam, 92c], expuesto en 5.2.1.2.1. Es un procedimiento de ruleta en el que la probabilidad de selección es proporcional a la calidad del individuo, medida mediante la función de aptitud antes descrita. Los operadores cruce y mutación mantienen también la misma estructura, con la salvedad de

<sup>42</sup> Como ya se ha indicado, la forma de medir los incumplimientos geométricos fue modificada por el mismo autor en [Tam et al., 98].

que la codificación de las distribuciones en LAYAGEN incluyen un gen al final de la cadena que representa el ratio de la planta, y que debe ser tratado de forma específica.

En el cruzamiento de individuos de  $n$  actividades el punto de cruce se selecciona aleatoriamente entre 1 y  $n$ , por lo que puede ocurrir que dos individuos intercambien únicamente el gen que indica el ratio de la planta. En la Figura 5.24 se muestra el procedimiento.

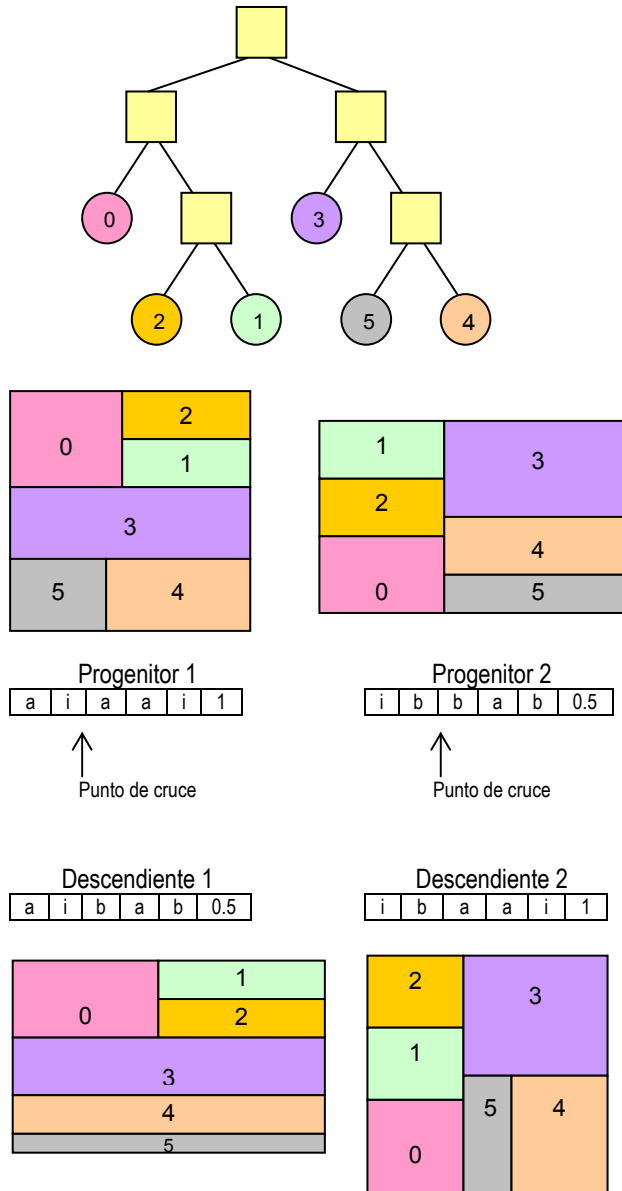


Figura 5.24: Cruce en la segunda fase de LAYAGEN.

El operador mutación selecciona de manera aleatoria un gen de la cadena y cambia su alelo aleatoriamente. En este caso el gen seleccionado puede ser el que indica el ratio de la planta. Si éste es el caso, el alelo seleccionado debe pertenecer al intervalo de ratios permitidos; si no es así, se escoge uno de los cuatro tipos de cortes.

#### **5.4. La propuesta de Kado, Ross y Corne**

En [Kado et al., 95] se plantea la disyuntiva de si es más eficaz (y eficiente) la agrupación de las actividades en un árbol de cortes fijo durante todo el proceso de búsqueda, o no restringir la búsqueda permitiendo al algoritmo alcanzar todo el espacio de soluciones. En el estudio se comparan los resultados obtenidos con el empleo de diferentes modos de *clustering*. Las conclusiones de dicho estudio son relevantes para el presente trabajo.

Se comparan las siguientes formas de agrupación:

**Método C1:** La codificación coloca las actividades al comienzo del cromosoma y los operadores de corte al final. La búsqueda no es restringida por un agrupación fija de actividades. Es, básicamente, el empleado en [Cohon et al., 91].

**Método T1:** Es el empleado por Tam en [Tam, 92c].

**Método DK1:** Es el empleado en [Dunlop et al., 85]. Emplea un procedimiento de *clustering* más sofisticado que el de Tam.

Los resultados obtenidos por el análisis parecen indicar que el empleo de una agrupación previa puede resultar negativo, sobre todo si dicha agrupación no es adecuada; sin embargo, especialmente en los problemas de cierta envergadura, el empleo de agrupaciones fijas de actividades resulta beneficioso, dado que si no se restringe la búsqueda el algoritmo no proporciona un buen rendimiento.

Los autores proponen por tanto, emplear un proceso inicial de *clustering* que sirva de guía al algoritmo en sus primeras etapas, pero permitir que la búsqueda evolucione hacia otras zonas dando libertad al algoritmo para modificar la agrupación. Sus propuestas son:

**Método T2:** Es el método T1, modificado de tal forma que los operadores genéticos pueden modificar la estructura del árbol.

**Método DK2:** Es el método T2, en el que se sustituye el método de *clustering* por el de DK1 [Dunlop et al., 85].

**Método TDK1:** Es el método T2 en el que se emplean los dos procedimientos de *clustering*, la mitad de la población se genera mediante el procedimiento de Tam y la otra mitad mediante el de Dunlop y Kernighan.

Los tres nuevos métodos propuestos mejoran los resultados de C1, T1 y DK1. El método TDK1 es el que mejores resultados proporciona de los 6 métodos evaluados. Se especula en el informe con que el empleo de dos técnicas de agrupación diferentes aumenta la diversidad de la población inicial, lo cual redundaría en una búsqueda más certera. En definitiva los autores concluyen que es positivo el empleo de procedimientos de *clustering* iniciales que sirvan de orientación al algoritmo, dando libertad a éste para modificar la estructura del árbol

de cortes posteriormente.

### **5.5. Otras propuestas y estudios destacables**

Ya se ha indicado que la bibliografía referente a la aplicación de los algoritmos genéticos al problema de distribución en planta es abundante. Pueden encontrarse multitud de variantes en las que se modifica la formulación del problema, la codificación de individuos, los modelos empleados o los operadores genéticos. A continuación se expone un listado somero y necesariamente incompleto:

En [Nissen, 94] se aplica los algoritmos genéticos sobre una formulación cuadrática de asignación del problema; en [Conway et al., 94] se usan en la resolución de la variante dinámica del problema, lo mismo que en [Balakrishnan et al., 03b], siendo en este caso un algoritmo híbrido; en [Tate et al., 95] se emplea un modelo de bahías flexibles que obtuvo resultados del problema de Armour y Buffa [Armour et al., 63] que sirvieron de referentes en métodos posteriores; en [Suresh et al., 95] se exponen nuevos procedimientos de cruce, y en [Islier, 98] se introduce el operador *inversión* en un algoritmo genético que emplea un codificación de los individuos en tres partes, y un mecanismo de reparación de individuos no factibles; en [Banerjee et al., 95] se desarrolla un algoritmo genético para resolver un problema de asignación, expresado como una variación de un formulación de programación entera mixta; en [Gau et al., 99] se presenta un algoritmo genético combinado con programación entera mixta que permite relajar las restricciones de búsqueda planteadas por la representación mediante árboles de cortes; una aplicación específica a un sector industrial concreto (farmacéutico) se expone en [Hamamoto et al., 99]; en [Azadivar et al., 00] se aplican a un modelo dinámico que considera el tiempo de transporte de materiales, el tiempo de ciclo de producción y la productividad como medida de la aptitud de las soluciones; el problema multiplanta es abordado en [Zhang et al., 02]; en [Balakrishnan et al., 03a] se presenta FACOPT, una aplicación informática que pretende facilitar el empleo de los algoritmos genéticos y el recocido simulado a los planificadores de plantas industriales; en [Wu et al., 02], en [Lee et al., 03] y en [Gómez et al., 03] se considera la necesidad del diseño de pasillos y corredores entre las actividades, la presencia paredes internas, etc.; en [Shayan et al., 04] se emplea la codificación descrita en [Hanafi, 00] para desarrollar un procedimiento que permite que los individuos de la población sean siempre factibles, sin necesidad de reparaciones o filtrados; en [Wang et al., 05] se emplea el análisis de varianza (ANOVA, comparaciones múltiples de Scheffe) para determinar el mejor tamaño del emplazamiento; el tema tratado en [Rajasekharan et al., 98] y en [Hicks, 04] se centra en las aplicaciones sobre células de fabricación flexible, tratando de minimizar los flujos de materiales para una agenda de trabajo dada en el segundo caso. Un análisis de la cuestión y una recopilación de métodos puede encontrarse en [Mavridou et al., 97] o en [Islier, 98].

En [Al Hakim, 00] se realiza una propuesta interesante, que introduce operadores genéticos especializados en la codificación propuesta por Tam en [Tam et al., 98]. Se expone a continuación con más detalle.

### 5.5.1 La propuesta de Al-Hakim

La codificación de los individuos propuesta por Tam en [Tam et al., 98] resulta una manera eficiente de introducir el árbol de cortes en el proceso evolutivo, haciendo posible alcanzar cualquier zona del espacio de soluciones. Sin embargo en [Al Hakim, 00] se critica la codificación de Tam alegando que restringe la aplicación de los operadores genéticos clásicos (cruce y mutación), dado que estos proporcionarán con mucha probabilidad individuos no factibles. Esto es así sobre todo, en la primera parte de la cadena (estructura del árbol) que debe cumplir siempre las tres características que se expusieron en 5.2.2. Al-Hakim hace notar que las dos últimas provocan que la probabilidad de obtener individuos no factibles sea muy elevada.

La segunda parte de la cadena (codificación de los nodos internos) no presenta dicho problema, aunque sí la tercera en la que se indican las actividades que ocupan las hojas del árbol. Esta parte de la cadena puede tener una longitud variable en función del individuo que representa, además, dado que un gen puede estar representado por varios bits, los operadores genéticos actuarían sobre partes de genes más que sobre genes completos. Se alega por otra parte que dichas estructuras presentan cierta ambigüedad en la decodificación, es decir, se crea cierta confusión en la obtención del individuo a partir de su codificación.

Al-Hakim propone el empleo de operadores cerrados, es decir, que preserven la factibilidad de los individuos generados. El trasplante (transplanting) consiste en cortar una rama de un árbol e introducirla en otra parte de la estructura (Figura 5.25).




Figura 5.25: Ejemplos de aplicación del operador trasplante (tomado de [Al Hakim, 00]).

El trasplante puede realizarse sin cambiar la localización de la rama, simplemente invirtiendo la posición de los nodos que penden directamente del nodo trasplantado (Figura

5.26). Esto tiene sentido dado que Tam define sólo dos tipos de corte en su segunda propuesta, quedando las actividades que penden de la rama izquierda del nodo colocadas en la parte izquierda del corte en caso de ser horizontal, y en la derecha las restantes, y quedando en la parte superior del corte si el corte es vertical.




Figura 5.26: Ejemplo de aplicación del operador transplante sin cambio de posición de la rama transplantada (tomado de [Al Hakim, 00]).

Otro operador propuesto por Al-Hakim es el cruce diagonal, en el que se emplean tres progenitores para dar lugar a tres descendientes. El proceso consiste en generar cada descendiente escogiendo de padres diferentes cada una de las tres partes que conforman la codificación completa. Así, de un padre se emplea la estructura del árbol, de otro los cortes en cada nodo y, finalmente, del restante progenitor, la posición de las actividades en las hojas del árbol.

El último operador es la clonación. Este operador fue propuesto con anterioridad en [Al Hakim, 99] y consiste en generar un nuevo individuo como imagen especular de su progenitor, lo cual aumenta la diversidad y evita la convergencia prematura de la población en óptimos locales.



# 6

**Metodología propuesta**

## 6. METODOLOGÍA PROPUESTA

### 6.1. Introducción

El problema de la distribución en planta de instalaciones se plantea como la colocación de un conjunto de departamentos de área conocida y desigual, sin que existan solapamientos, en una región plana de dimensiones conocidas, de tal forma que se minimicen los costes asociados a la interacción entre ellos. Los costes asociados a la distribución de los departamentos reflejan, en este caso, tanto costes de transporte de materiales entre las instalaciones ubicadas en cada departamento, como los derivados del incumplimiento de ciertas preferencias de carácter cualitativo o cuantitativo, como por ejemplo, la necesidad de adyacencia entre determinadas instalaciones derivadas del propio sistema productivo o la existencia de condiciones que garanticen la seguridad e higiene en el trabajo.

Tras la revisión del estado de la cuestión, el autor de este trabajo propone a continuación una definición alternativa del problema, que pretende, recogiendo su carácter multicriterio, introducir un enfoque sistémico que, además, contemple en alguna medida la gran cantidad de restricciones que debe cumplir cualquier solución viable:

*El problema de la distribución en planta de instalaciones industriales es el que plantea la forma de asigna, a las actividades que conforman un proceso productivo, el espacio requerido para su normal desarrollo (tamaño, posición y forma), de manera que el proceso logre la mayor eficiencia posible medida bajo todos los criterios oportunos, y se atenga a todas las restricciones concurrentes en la realidad.*

Los diferentes factores a considerar en la evaluación de las soluciones aconsejan, desde luego, que el problema sea abordado desde una perspectiva multicriterio [Muther, 68; Tompkins et al., 84; Malakooti, 89], sin embargo, diferentes autores reconocen como fundamental la minimización del coste derivado del transporte de materiales entre las instalaciones [Lawler, 63; Tompkins et al., 84; Matson et al., 92; Sule, 00], e incluso quien opina que los gastos totales de las operaciones de fabricación pueden ser atribuidos casi exclusivamente al transporte de materiales [Cameron, 52]. En [Tompkins et al., 84] se afirma que entre el 20 y el 50% de los gastos totales de las operaciones de fabricación pueden ser atribuidos al transporte de materiales, y que una adecuada distribución de las actividades puede reducir estos costes en, al menos, entre un 10 y un 30%. En [Sule, 94] e [Islier, 98] este porcentaje se sitúa entre el 30 y el 75% de los gastos totales de las operaciones de fabricación. En [Matson et al., 92] el porcentaje es del 60% y en [Immer, 53] del 40.

Estas consideraciones, junto con la dificultad intrínseca de los modelos multicriterio [Raoot et al., 93a], provoca que la mayor parte de los métodos presentados en la bibliografía afronten el problema desde una perspectiva mono-objetivo [Current et al., 90], en los que se minimiza únicamente el coste debido al transporte de materiales entre los diferentes departamentos. Excepciones a esto son, por ejemplo, los métodos expuestos en [Rosenblatt, 79; Rosenblatt et al., 86; Malakooti, 89; Harmonosky et al., 92; Meller et al., 96b; Islier, 98; Chen et al., 99; González-García, 05; Ontiveros, 05]. Resulta evidente que el grado de

aplicabilidad inmediata de las soluciones obtenidas de un método aumentará en función del número de criterios contemplados en la búsqueda de soluciones al problema. Cuantas más consideraciones se realicen tratando de reflejar en el modelo del problema los condicionantes que afectan a una planta real, más sencilla será su posterior implantación.

Dentro de todos los posibles objetivos a cumplir en la búsqueda de la distribución óptima existe uno que en este trabajo se considerará *conditio sine qua non*; para que las soluciones obtenidas sean aplicables en la realidad, es indispensable que estén sujetas y cumplan determinadas restricciones geométricas. La forma de los diferentes departamentos debe permitir la colocación en su interior de las máquinas que la ocuparán y el desarrollo normal de la actividad de los trabajadores. Esto significa que la forma de los diferentes departamentos debe ajustarse a las necesidades espaciales de cada actividad. En este trabajo se considera que sin el cumplimiento de esta condición ninguna solución tiene validez, dado que no puede posteriormente ser implementada, sino con gran cantidad de reajustes manuales que modifican completamente la solución obtenida [Levary et al., 85; Kusiak et al., 87].

El área y la forma adecuada para cada instalación pueden estimarse a partir de los datos proporcionados por los ingenieros de producción. Habitualmente se precisan áreas rectangulares, estableciéndose unos límites máximos y mínimos en la esbeltez de la forma de los departamentos fuera de los cuales se consideran inaceptables. En general, la distribución espacialmente más eficiente será aquella en la que la forma de los




Figura 6.1: Solución al problema de Armour & Buffa [Armour et al., 63] propuesta en [Wang et al., 05].

departamentos se ajuste lo máximo posible a las necesidades reales de la actividad a desarrollar en él. Esto es especialmente importante en los problemas de distribución en

planta para sistemas de fabricación celular y *sistemas de fabricación flexible*, en los que las áreas y formas de las instalaciones están predeterminadas (fijas), y sólo se debe definir su posición y orientación [Kim et al., 00].

Como se indica en [Levary et al., 85; Kusiack et al., 87; Tam et al., 98], gran parte de los trabajos realizados sobre el tema han ignorado las restricciones geométricas, o establecen intervalos de validez irrealmente grandes para los ratios de los departamentos. Esto es más así cuando se emplean técnicas discretas que dan lugar a áreas para las actividades con formas complejas y difícilmente aprovechables. En la Figura 6.1 se muestra la solución ofrecida en [Wang et al., 05] al problema de Armour & Buffa [Armour et al., 63], obtenida mediante el empleo de técnicas discretas. Difícilmente una solución como ésta podría implementarse en la realidad, dado que la forma de las áreas 7, 8 y 9 haría prácticamente imposible que albergaran actividad industrial alguna, y partes de las áreas 1 y 17 no son aprovechables en modo alguno.

Son las técnicas que emplean modelos continuos como las basadas en estructuras de cortes o en bahías flexibles las que proporcionan soluciones con áreas más regulares, compactas, y con gran aprovechamiento del espacio (sin áreas muertas). La gran compacidad de las distribuciones obtenidas redundará en una disminución de las distancias entre las actividades y, por lo tanto, en los costes derivados del transporte de materiales.




Figura 6.2: Solución a un problema de 12 actividades en [Shayan et al., 04].

Sin embargo, si no se establecen las medidas adecuadas para controlar las características geométricas de las soluciones, la excesiva esbeltez de los departamentos puede hacer inviable la implantación. En la Figura 6.2 se muestra la solución a un problema de 12 actividades obtenida mediante técnicas continuas en [Shayan et al., 04]. Puede apreciarse que muchas de las áreas asignadas a las actividades poseen formas poco operativas si no es para actividades que específicamente así lo requieran.

Dentro de las diferentes técnicas para la resolución del problema de distribución en planta, las basadas en algoritmos genéticos han ofrecido mejores resultados que otro tipo de métodos, y dentro de este grupo, las que emplean modelos continuos, basándose en árboles de corte, en bahías flexibles o en matrices de localización, resultan especialmente eficientes en la búsqueda de soluciones geoméricamente aceptables. Por el modo de construir las distribuciones, las técnicas basadas en árboles de corte permiten cubrir un espacio de soluciones mayor que las basadas en bahías flexibles o en matrices. De hecho, el espacio de soluciones explorables mediante estos dos métodos es un subconjunto del espacio de soluciones que es posible abordar mediante árboles de corte. Cualquier solución obtenida mediante bahías flexibles o matrices se puede obtener mediante árboles de corte, no siendo así a la inversa.

Así pues, dada la intención del presente trabajo de elaborar una metodología que permita la obtención de soluciones al problema de distribución en planta con un elevado

control de la geometría de las actividades, parece lógico emplear algoritmos genéticos aplicados sobre un modelo continuo geoméricamente eficiente como los árboles de corte.

### **6.1.1 Técnicas en una fase versus técnicas en dos fases en el control geométrico de las actividades**

La información contenida en un árbol de cortes indica la forma en la que se construye la solución mediante cortes recursivos del dominio de ubicación. Para generar un árbol de cortes se deben agrupar los ítems a distribuir en función de los criterios escogidos para evaluar las soluciones. Son diversos los métodos empleados para realizar la agrupación, yendo desde las técnicas numéricas de *clustering* hasta las heurísticas.

El árbol de cortes no representa en sí una única solución, sino un grupo de soluciones accesibles mediante la posterior determinación de la manera en que se llevará a cabo el corte en cada nodo del árbol para generar los diferentes espacios. Sin embargo, a pesar de que la definición del árbol de cortes no determina completamente la solución del problema, una vez precisado, sólo una pequeña parte del espacio de soluciones podrá ser alcanzado por la búsqueda del algoritmo, dado que la adyacencia entre las áreas reservadas a cada actividad está prácticamente definida por la estructura del árbol. Por ello, para evitar que el árbol de cortes escogido conduzca a limitar la búsqueda a zonas del espacio, en las que no existen buenas soluciones desde el punto de vista de alguno de los criterios empleados en la evaluación, es imprescindible que la generación de la estructura del árbol de cortes se lleve a cabo considerando todos los criterios que posteriormente son utilizados para evaluar las soluciones.

En la primera propuesta de Tam [Tam, 92c], se adopta una metodología en dos fases. En la primera se trata de obtener la estructura de un árbol de cortes aplicando técnicas numéricas de *clustering* (usando el *average linkage method*). La agrupación de los departamentos refleja únicamente los requerimientos de proximidad entre las actividades en función del tráfico de materiales entre ellas. Posteriormente, en la segunda fase, este árbol es empleado por un algoritmo genético para localizar la mejor distribución que es capaz de generar.

Dado que el árbol de cortes seleccionado en la primera fase determina de manera notable la segunda, Santamarina [Santamarina, 95] propone realizar una cuidadosa búsqueda del árbol de cortes. Para ello establece un método en dos fases en el que la primera localiza el árbol óptimo mediante un algoritmo genético. Para ello establece, como ya se vio, la manera de medir la capacidad del árbol de cortes para generar distribuciones de bajo coste relacional (potencial del árbol de cortes). En la segunda fase es de nuevo un algoritmo genético el que localiza la mejor distribución que es capaz de generar el árbol obtenido en la fase uno.

Los métodos en varias fases no son privativos de los algoritmos genéticos, en [Chen et al., 02] por ejemplo, se presenta un método en dos fases que emplea *multidimensional scaling* y recocido simulado.

Ninguno de estos métodos en dos fases incluye la consideración del criterio geométrico en la búsqueda del árbol de cortes óptimo (primera fase). El problema es abordado considerando las restricciones geométricas posteriormente en la segunda fase, en el

momento de determinar los cortes de cada nodo. Sin embargo, puede ocurrir que ninguna de las distribuciones que pueda generar ese árbol cumpla plenamente dichas restricciones; es decir, que el subespacio de soluciones a que ha limitado la búsqueda no posea distribuciones que cumplan los requerimientos geométricos de las actividades.

El método de Santamarina es una mejora sustancial del de Tam, logrando distribuciones que atienden a múltiples criterios y considerando la forma de la planta como una variable del problema. Pero ninguno de los dos métodos considera el criterio geométrico en la fase de obtención del árbol de cortes óptimo, lo que conduce a que la búsqueda de distribuciones para un determinado árbol pueda ser infructuosa. Este problema se obvia debido a que un árbol de cortes puede dar lugar a múltiples distribuciones en función del tipo de corte que se realice en cada nodo, resultando difícil saber a priori si alguna de ellas cumplirá dichas restricciones.

La propuesta inicial de Tam fue modificada por él mismo posteriormente [Tam et al., 98]. Se indica en este segundo artículo que el empleo de un árbol fijo, en el proceso de búsqueda de la distribución óptima, sólo puede cubrir una parte del espacio de posibles soluciones. La nueva propuesta fue un método en una sola fase, en la que un algoritmo genético genera simultáneamente la estructura del árbol de cortes y la distribución que de él se obtiene, estableciendo el tipo de corte en cada nodo. Así pues, el algoritmo debe optimizar de manera simultánea la estructura del árbol, el tipo de corte en cada nodo y las actividades que ocupan cada hoja del árbol. De esta manera no se limita la búsqueda a una zona del espacio de soluciones sino que el algoritmo puede alcanzar cualquier solución al problema que se generable mediante un árbol de cortes.

En este procedimiento en una única fase, y en sus posteriores modificaciones y adaptaciones (por ejemplo [Gau et al., 99; Al Hakim, 00; Hanafi, 00; Wu et al., 02]) la evaluación de la calidad del árbol de cortes desde el punto de vista geométrico es realizada de manera indirecta a partir de la calidad de la distribución que de él se obtiene. Es decir, si una determinada cadena representa un árbol de cortes y una distribución de él obtenida que cumple los criterios geométricos, es obvio que dicho árbol es capaz de generar distribuciones geoméricamente aceptables. No obstante, el problema de este sistema es que una determinada cadena que represente un árbol de muy elevada calidad geométrica, puede estar acompañado por unos tipos de cortes que dan lugar a una mala distribución, por lo que el conjunto será valorado negativamente y sus probabilidades de subsistir y reproducirse son bajas.

El problema que los métodos en una fase tratan de resolver puede no serlo si se enfoca desde otra perspectiva. Aunque los métodos en una fase limitan el espacio de soluciones accesibles por el algoritmo, esto puede resultar beneficioso si esa limitación se realiza sobre una zona especialmente prometedora del espacio de soluciones. Los métodos en una fase pueden acceder a todo el espacio, por lo que la zona a explorar es mucho más grande y por lo tanto la búsqueda menos exhaustiva. Los resultados ofrecidos en [Kado et al., 95], indican que los eficacia de los métodos que permiten modificar la agrupación de actividades, mejoran si se parte de poblaciones que responden a agrupaciones realizadas con diversos métodos.

En la Figura 6.3a se ha representado una idealización del espacio de soluciones de un problema y la localización del óptimo global. Los métodos monofásicos deben explorar todo

el espacio en la búsqueda de buenas soluciones. En la Figura 6.3b se aprecia que el empleo de un método en dos fases provoca la restricción del espacio de búsqueda a zonas específicas, aquellas a las que es posible acceder empleando el árbol de cortes obtenido en la primera fase.

Si la selección del árbol de cortes en la primera fase no se realiza de manera conveniente, el subespacio de búsqueda de la segunda fase será incapaz de proporcionar buenas soluciones (*subespacio 1* en la Figura 6.3b). En cambio, si el árbol de cortes es adecuado bajo el prisma de los diferentes criterios que se emplearán en la evaluación de las distribuciones que genere, la búsqueda se centrará en una zona conveniente (en la Figura 6.3b el *subespacio 2*), y la probabilidad de obtener una buena solución al problema es muy elevada. Como se muestra en dicha figura, el óptimo global del problema puede resultar inalcanzable al quedar fuera del subespacio de búsqueda, pero se garantiza que en dicho subespacio hay soluciones de calidad aceptable más fácilmente localizables que con un método monofásico no restringido.

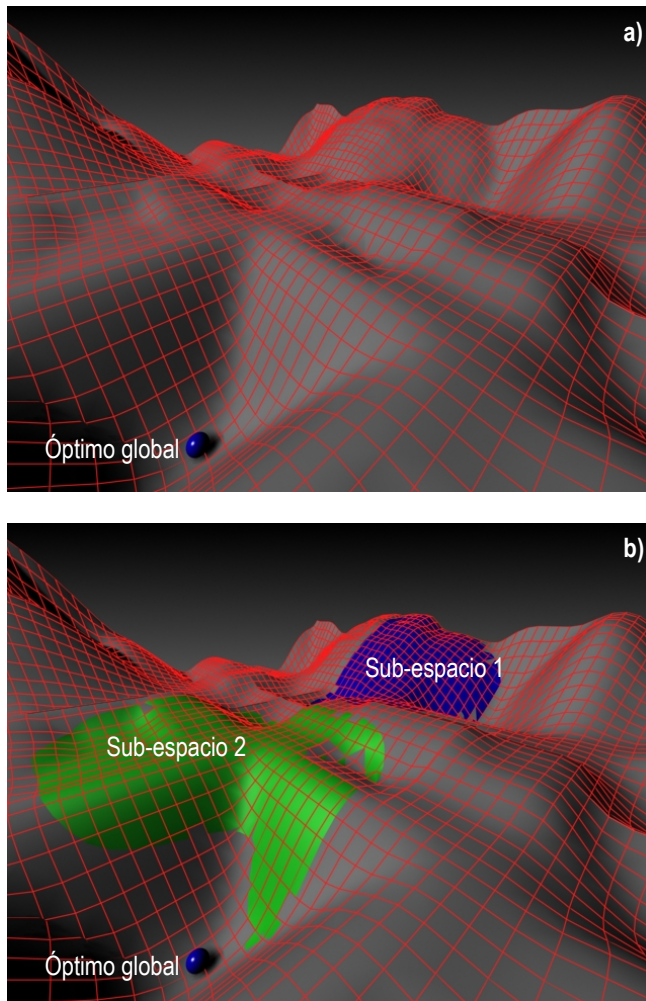


Figura 6.3: Espacios de soluciones en métodos monofásicos (a) y bifásicos (b).

Este tipo de estrategias “*divide y vencerás*” han resultado eficientes, por ejemplo, en el problema de distribución *multifloor*, donde se ha demostrado que las técnicas en dos fases (seleccionar primero la planta a la que se destina cada actividad y después distribuir las actividades en sus plantas), proporcionan mejores resultados que las técnicas monofase (optimizar simultáneamente la planta a la que se asigna cada actividad y la distribución de las actividades en las plantas) [Meller et al., 97]. Otro ejemplo es el procedimiento jerárquico empleado por Tam y Li [Tam et al., 91], que divide la resolución de un problema de distribución de gran cantidad de actividades en varios sub-problemas pequeños.

Así pues, el empleo de una técnica bifásica puede resultar conveniente si logra que la primera fase proporcione un árbol de cortes óptimo, desde el punto de vista de todos los criterios que se empleen posteriormente para evaluar las distribuciones obtenidas en la segunda fase.

### 6.1.2 La evaluación de la calidad geométrica del árbol de cortes

El problema fundamental que se plantea en la técnica en dos fases de Santamarina es encontrar la manera de evaluar los árboles de corte. Un árbol de cortes debe ser considerado más apto que otro si es mayor su capacidad para generar distribuciones que cumplan con los diversos criterios con los que se éstas se evaluarán.

Como se vio en el capítulo anterior, el algoritmo LAYAGEN de Santamarina emplea el “Potencial del Árbol de Cortes” para evaluar los árboles. Este indicador permite valorar el grado en que un determinado árbol permitirá la cercanía de las actividades que lo requieran en las distribuciones que genere. Sin embargo, no se valora en modo alguno si las distribuciones aceptables desde el punto de vista relacional que genere, lo serán también desde el punto de vista geométrico.

En su primera propuesta, Tam insinúa una forma de mantener el control geométrico de las actividades mediante la estructura del árbol de cortes. Propone que los árboles desequilibrados deben ser evitados porque es muy probable que den lugar a particiones muy delgadas, que violarían las restricciones geométricas de esas actividades. Por ello, propone emplear el *average linkage method* como procedimiento de *clustering*, dado que produce árboles de estructura más balanceada. Sin embargo, aunque es posible mantener el control




Figura 6.4: Distribución de actividades que requiere de un árbol de cortes desequilibrado.



geométrico de las actividades en los árboles equilibrados cuando éstas requieren áreas similares y ratios de forma parecidos, es más difícil mantener dicho control cuando aumenta la variación relativa entre las áreas requeridas por las actividades o sus ratios geométricos. Por otra parte, existen casos particulares en los que se hace necesario el uso de árboles desequilibrados, como por ejemplo el representado en la Figura 6.4.

Ésta no es, evidentemente una buena fórmula para evaluar la calidad geométrica de un árbol de cortes. Así pues, la metodología que se presenta propondrá un indicador que permitirá evaluar de forma cuantitativa, la capacidad de un árbol de cortes para obtener de él distribuciones que cumplan con las restricciones geométricas impuestas a todas las actividades, antes de conocer qué tipo de cortes se realizarán en cada nodo, y que será empleada como parte de la función de aptitud de un algoritmo genético en dos fases basado en LAYAGEN (denominado LAYAGEN G) que será expuesto posteriormente. El indicador propuesto permitirá mantener el control geométrico de las actividades independientemente de la homogeneidad en las áreas y los ratios de aspecto requeridos por las actividades, así como del grado de desequilibrio del árbol estudiado. Por otra parte, LAYAGEN G será capaz de considerar el ratio de aspecto de la planta como variable del problema a optimizar, por lo que el indicador desarrollado deberá ser capaz de medir la aptitud geométrica de un árbol para todos los ratios de planta posibles.

En apartados siguientes se describirá dicho indicador, al que se denominará “Potencial Geométrico del Árbol de Cortes”, y se propondrá una función evaluadora que combinará este potencial con el descrito por Santamarina que permite evaluar la calidad relacional de los árboles. Esta función servirá como función de aptitud para la primera fase del algoritmo LAYAGEN G que se expondrá en apartados posteriores. De esta manera será posible intensificar la búsqueda en aquellos árboles de corte prometedores desde el punto de vista geométrico, y descartar aquellos incapaces de cumplir las restricciones de forma independientemente de los cortes que se realicen.

## **6.2. Hipótesis planteadas para el desarrollo de la metodología**

El objetivo fundamental de este trabajo, planteado en capítulo inicial, es el desarrollo de una metodología de resolución del problema de distribución en planta que permita la obtención de soluciones eficientes bajo un prisma multicriterio, siempre con un elevado control de la geometría de las actividades. Analizada la bibliografía existente sobre el tema, de la que se ha realizado una amplia exposición, y bajo las premisas planteadas en los apartados precedentes, se plantean a continuación las hipótesis que servirán de base a la metodología que se propone.

**Hipótesis 1:** En la búsqueda de soluciones al problema de distribución en planta de actividades de área desigual, el empleo de una estrategia en dos fases, en la que en la primera se realiza la agrupación de las actividades por afinidad multicriterio en una estructura de cortes, y en la segunda se definen la forma de dichos cortes, puede resultar más eficaz que una búsqueda irrestricta, si se realiza la agrupación considerando todos los criterios, incluido el geométrico, que posteriormente se emplearán en la medición de la bondad de las distribuciones.

**Hipótesis 2:** En un planteamiento del tipo expuesto en la hipótesis 1, la segunda etapa está fuertemente determinada por el resultado de la primera, por lo que es preferible emplear una mayor cantidad de tiempo y recursos en la localización de una agrupación oportuna de las actividades, aún a costa de disminuir los dedicados a la segunda fase.

**Hipótesis 3:** Es posible definir un indicador de la capacidad de un árbol de cortes para generar distribuciones, en las que las áreas asignadas a las actividades cumplan los requerimientos geométricos que les han sido impuestos. Para ello es necesario poder establecer alguna relación entre la forma de un dominio y la forma de los subdominios generados por la división de aquel, y emplear un procedimiento constructivo del indicador de carácter recursivo, similar al empleado al construir las distribuciones mediante cortes a partir del árbol. Este indicador podrá ser empleado como parte de una función de evaluación de árboles de corte.

**Hipótesis 4:** Entre todas las posibles combinaciones de tipos de cortes que se pueden establecer para generar una distribución en planta a partir de un árbol de cortes, un algoritmo genético será capaz de discriminar la óptima (o al menos una sub-óptima), desde el punto de vista del cumplimiento de las restricciones geométricas impuestas a las actividades. Como se expondrá posteriormente, esta suposición es necesaria para la construcción de un indicador del tipo planteado en la Hipótesis 3.

**Hipótesis 5:** La introducción en el algoritmo de mecanismos de intensificación de la búsqueda, el empleo de estrategias elitistas, y la introducción de conocimiento específico del problema en los operadores de corte, redundará en una mayor eficacia de la búsqueda.

A lo largo del presente capítulo y en el dedicado a los resultados y conclusiones se comprobará la validez de dichas hipótesis. En los puntos siguientes se expone la metodología propuesta.

### 6.3. Potencial geométrico del árbol de cortes

Las diferentes estructuras de los árboles de corte determinan la forma en la que se agrupan las actividades. Esto a su vez determina las distribuciones que es posible obtener de dicho árbol mediante los sucesivos cortes. Es posible determinar la capacidad de un árbol dado para generar distribuciones de bajo coste relacional mediante el ya definido *potencial relacional* del árbol de cortes. Para evaluar la capacidad de dicho árbol para componer distribuciones cuyas actividades cumplan con las restricciones geométricas se introduce a continuación el *potencial geométrico* del árbol de cortes. Para ello se comienza definiendo dicho potencial para un árbol de cortes básico, formado por un nodo y dos actividades que penden de él, generalizando posteriormente dicha definición a árboles más complejos.




Figura 6.5: Árbol de cortes básico.

### 6.3.1 Potencial geométrico de un árbol de cortes básico

Denominaremos *árbol de cortes básico* a aquél formado únicamente por dos actividades y que, por tanto, penden de un único nodo (que será el nodo raíz). Sean dos actividades a las que denominaremos **1** y **2**; sean  $A_1$  y  $A_2$  las áreas de dichas actividades; y sean  $r_{1min}$ ,  $r_{1max}$ ,  $r_{2min}$  y  $r_{2max}$  los ratios de aspecto mínimos y máximos deseados para cada actividad. La generación de distribuciones en planta de estas dos actividades se realiza dividiendo el dominio de ubicación mediante un único corte. El árbol de cortes que genera dichas

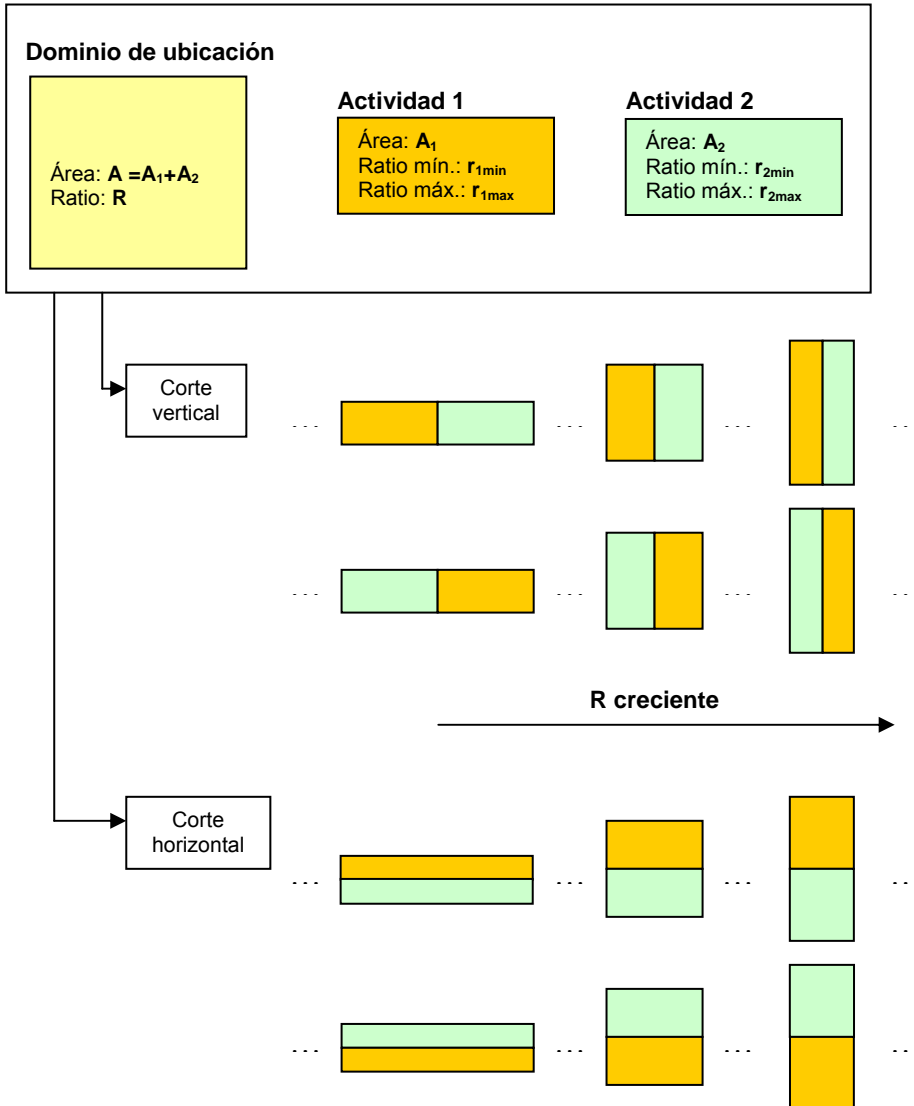


Figura 6.6: Posibles configuraciones generadas por un corte en un árbol de cortes básico.

distribuciones es un *árbol de cortes básico* que queda representado en la Figura 6.5. El área del dominio de ubicación (**A**) será igual a la suma de las áreas de las actividades **A<sub>1</sub>** y **A<sub>2</sub>**, y denominaremos **R** al ratio alto-ancho de dicho dominio. En la Figura 6.6 se representan todas las posibles configuraciones que es posible obtener al cortar el dominio inicial vertical u horizontalmente en función del ratio alto-ancho del dominio inicial (**R**).

Pueden establecerse las siguientes relaciones entre el ratio de las actividades obtenidas tras el corte (**r<sub>1</sub>** y **r<sub>2</sub>**) y el ratio del dominio de partida **R**:

En caso de corte vertical:

$$r_1 = \frac{A_1 + A_2}{A_1} R = \frac{A}{A_1} R \qquad r_2 = \frac{A_1 + A_2}{A_2} R = \frac{A}{A_2} R$$

En caso de corte horizontal:

$$r_1 = \frac{A_1}{A_1 + A_2} R = \frac{A_1}{A} R \qquad r_2 = \frac{A_2}{A_1 + A_2} R = \frac{A_2}{A} R$$

Definido el ratio alto-ancho como el cociente entre la altura y la anchura del área de la actividad o dominio considerado, éste puede tomar valores comprendidos en el intervalo  $]0, \infty[$ , estando un dominio cuadrado situado en el valor 1 (ver Figura 6.7). Así pues, las

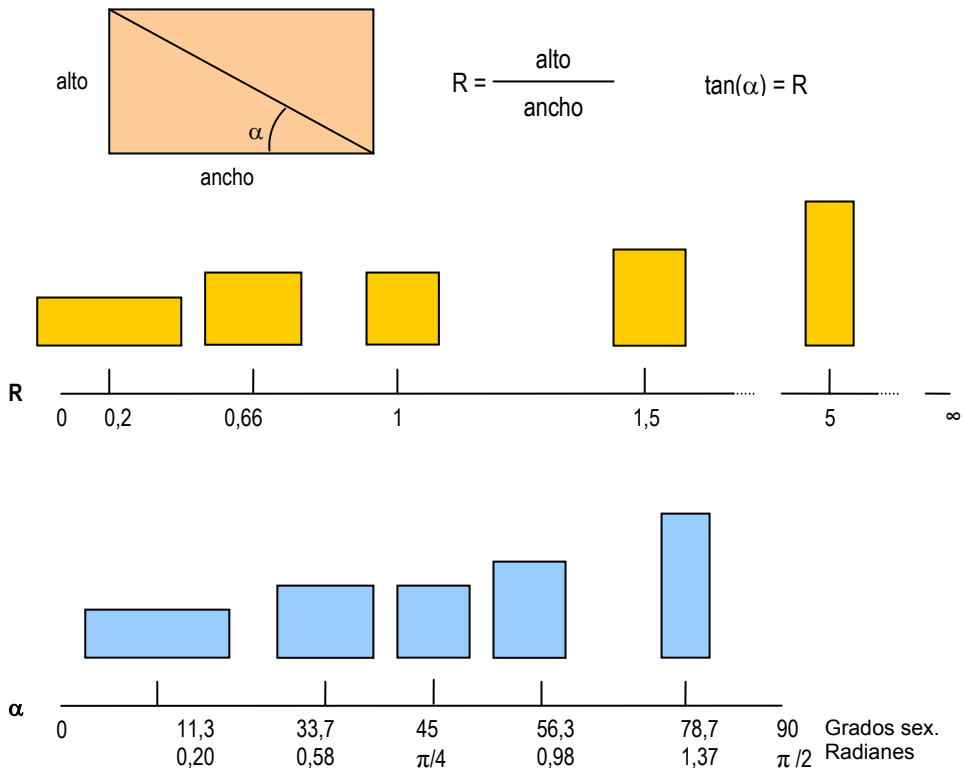


Figura 6.7: Medición de la forma de un dominio mediante ratios alto-ancho y mediante ángulos.

ecuaciones anteriores son del tipo  $f(R): ]0, \infty[ \rightarrow ]0, \infty[$ , resultando poco operativas, debido al tamaño de su dominio de definición y a su asimetría, para los cálculos que a continuación se expondrán. Por otra parte el tratamiento informático de este tipo de funciones puede resultar complejo y poco eficiente.

Así pues, se propone medir la geometría de la zona destinada a una actividad mediante el ángulo ( $\alpha$ ) formado por las diagonales del rectángulo y la horizontal. Dado que  $R$  se define como el cociente entre el cateto opuesto al ángulo medido y el cateto contiguo, y dicha definición coincide con la de la tangente del ángulo  $\alpha$  (ver Figura 6.7), podemos aplicar la transformación:

$$\tan(\alpha) = R;$$

De esta manera las ecuaciones anteriores quedarían de la forma:

- En caso de corte vertical:

$$\alpha_1 = \arctan\left(\frac{A}{A_1} \tan \alpha\right) \quad \alpha_2 = \arctan\left(\frac{A}{A_2} \tan \alpha\right)$$

- En caso de corte horizontal:

$$\alpha_1 = \arctan\left(\frac{A_1}{A} \tan \alpha\right) \quad \alpha_2 = \arctan\left(\frac{A_2}{A} \tan \alpha\right) \quad \text{Ec. 6.1}$$

Estas funciones están ahora definidas de la forma  $f(\alpha): ]0, \pi/2[ \rightarrow ]0, \pi/2[$ , y son simétricas respecto a la actividad cuadrada ( $\alpha=\pi/4$ ) que ocupa la posición central del dominio de definición (Figura 6.7).<sup>43</sup>

### 6.3.1.1 Incumplimiento formal de las actividades

Una vez conocida la relación entre el ángulo del dominio de partida y los ángulos de las actividades resultantes del corte, y dado que se conocen los ratios máximos y mínimos permitidos para cada actividad, es posible valorar el grado de cumplimiento de dichas restricciones en función del ratio del dominio inicial. Para ello habrá que diferenciar entre actividades de orientación libre y actividades de orientación fija (predominantemente vertical u horizontal), y establecer la forma de codificar dicha orientación. Una actividad es libre cuando, dado un sistema de referencia, su orientación respecto a éste puede ser vertical u horizontal de forma indistinta, sin impedir su normal desarrollo. Una actividad será fija en caso contrario.

<sup>43</sup> A partir de este punto del texto, y para facilitar la comprensión por parte del lector, los ángulos serán medidos en grados sexagesimales. No obstante, en la implementación informática del método se emplearon radianes como unidad de medida de ángulos.




Figura 6.8: Codificación de las actividades.

Debido a los cálculos que a continuación se desarrollarán se hace necesario definir el siguiente criterio de codificación de actividades (Figura 6.8):

**Actividades de orientación libre:** se codificarán indicando el intervalo  $[r_{\min}, r_{\max}]$  de variación posible del ratio en caso de ser horizontales, marcándolas posteriormente como de orientación libre. En este tipo de actividades se considerará que el ratio válido estará

comprendido en  $[r_{i \min}, r_{i \max}] \cap [1/r_{i \max}, 1/r_{i \min}]$  (o expresado en ángulos  $[\alpha_{i \min}, \alpha_{i \max}] \cap [90 - \alpha_{i \max}, 90 - \alpha_{i \min}]$ ). En el caso de actividades de orientación libre debe cumplirse que el punto central del intervalo de ratios permitidos sea inferior o igual a 1 (45°).

**Actividades de orientación fija horizontal o vertical:** se codificarán indicando el intervalo  $[r_{i \min}, r_{i \max}]$  de variación posible del ratio, y definiéndolas como de orientación fija. Diremos que una actividad fija cumple las restricciones geométricas cuando su ratio  $r_i$  pertenece al intervalo  $[r_{i \min}, r_{i \max}]$ . En caso de emplear ángulos una actividad de ratio  $\alpha_i$  cumple las restricciones geométricas si pertenece al intervalo  $[\alpha_{i \min}, \alpha_{i \max}]$

Para las actividades de orientación libre, la valoración del incumplimiento de las restricciones geométricas se llevará a cabo midiendo la distancia entre el ratio de la actividad y el extremo del intervalo de validez más cercano (Figura 6.9), como refleja la siguiente expresión en la que  $\alpha_i$  es el ratio de la actividad:

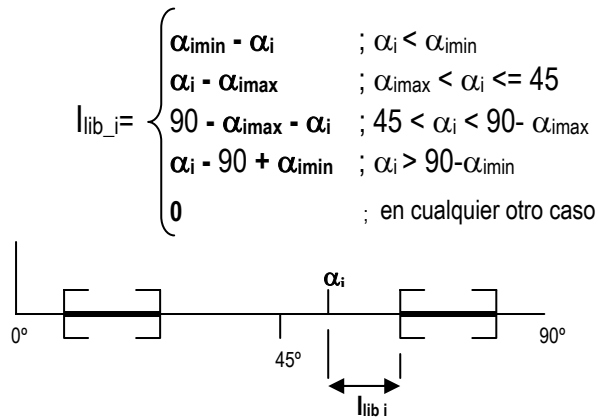


Figura 6.9: Medición del incumplimiento formal de una actividad de orientación libre.

Dado que existe simetría de los intervalos de validez respecto del punto  $\alpha_i=45^\circ$ , la expresión anterior puede simplificarse con la correspondiente traslación del origen a ese punto, resultando que el incumplimiento puede medirse con la expresión:

$$I_{lib\_i} = \left| \alpha_i - 45 \right| - \left[ 45 - \frac{\alpha_{i \min} + a}{2} \right] - \frac{a - \alpha_{i \min}}{2} \quad \text{Ec. 6.2}$$

en la que  $a$  toma el valor  $\alpha_{i \max}$  si éste es menor que 45 y en caso contrario toma el valor 45.

La forma de la Ec. 6.2 proporciona valores negativos en caso de que el ratio de la actividad pertenezca al intervalo de ratios permitidos. El valor será más negativo cuanto más centrado esté el ratio en dicho intervalo. Esto proporciona la posibilidad de primar las soluciones cuyas actividades, no sólo minimicen el incumplimiento formal, sino que, además, tegán ratios lo más cercanos posible al centro de los intervalos. Esto puede resultar de utilidad cuando, a pesar de existir cierta tolerancia formal, sea preferible que las actividades se desvien lo mínimo posible de un valor central. Como alternativa, puede asignarse un valor

de 0 a  $I_{lib}$  si éste resulta negativo, valorando de la misma manera cualquier ratio que pertenezca a los intervalos de tolerancia. En la implementación informática del algoritmo se contemplaron las dos posibilidades, dejando a criterio del planificador emplear una valoración u otra.

En el caso de **actividades de orientación fija** la valoración del incumplimiento de las restricciones geométricas se llevará a cabo de una manera similar, considerando ahora que si se trata de una actividad de orientación vertical,  $\alpha_{imin}$  y  $\alpha_{imax}$  serán sustituidos por  $90-\alpha_{imax}$  y  $90-\alpha_{imin}$  respectivamente, y  $\alpha_i$  por  $90-\alpha_i$ :

$$I_{fij\_i} = \begin{cases} \alpha_{imin} - \alpha_i & ; \alpha_i < \alpha_{imin} \\ \alpha_i - \alpha_{imax} & ; \alpha_i > \alpha_{imax} \\ 0 & ; \alpha_{imin} \geq \alpha_i \geq \alpha_{imax} \end{cases}$$




Figura 6.10: Medición del incumplimiento formal de una actividad de orientación fija.

De nuevo esta expresión puede ser simplificada trasladando el origen de ángulos al centro del intervalo logrando su simetría respecto al origen:

$$I_{fij\_i} = \left| \alpha_i - \frac{\alpha_{imin} + \alpha_{imax}}{2} \right| - \frac{\alpha_{imax} - \alpha_{imin}}{2} \quad Ec. 6.3$$

Como en el caso de la Ec. 6.2 el resultado de  $I_{fij\_i}$  puede ser negativo en caso de que  $\alpha_i$  pertenezca al intervalo de ratios permitidos. En caso de no desear este comportamiento se asignará el valor 0 a  $I_{fij\_i}$  si éste es negativo.

Las ecuaciones Ec. 6.2 y Ec. 6.3 permiten valorar el incumplimiento geométrico de una actividad de ratio  $\alpha_i$  dados los ratios mínimos y máximos permitidos. Como se indicó anteriormente, el ratio  $\alpha_i$  de una actividad depende del ratio del dominio de partida  $\alpha$  que genera el área de la actividad mediante un corte horizontal o vertical según las ecuaciones Ec. 6.1. Así pues, es posible valorar el incumplimiento formal de las actividades generadas por el corte en función del ratio del dominio inicial  $\alpha$  mediante las siguientes ecuaciones:

$$I_{lib\_i}(\alpha) = \left| \arctan(K \tan \alpha) - 45 \right| - \left[ 45 - \frac{\alpha_{imin} + a}{2} \right] - \frac{a - \alpha_{imin}}{2}$$

$$I_{fij\_i}(\alpha) = \left| \arctan(K \tan \alpha) - \frac{\alpha_{imin} + \alpha_{imax}}{2} \right| - \frac{\alpha_{imax} - \alpha_{imin}}{2} \quad Ec. 6.4$$



donde:

- $I_{lib,i}$  es el incumplimiento formal de la actividad de orientación libre  $i$  en función del ratio del dominio inicial;
- $I_{fij,i}$  es el incumplimiento formal de la actividad de orientación fija  $i$  en función del ratio del dominio inicial;
- $\alpha$  es el ratio del dominio de partida;
- $\alpha_{imax}$  es el ratio máximo permitido para la actividad considerada;
- $\alpha_{imin}$  es el ratio mínimo permitido para la actividad considerada;
- $a$  toma el valor  $\alpha_{imax}$  si éste es menor que 45 y en caso contrario toma el valor 45;
- $K$  es el cociente entre área de la actividad considerada y el área del dominio de partida en caso de corte vertical, y el inverso de éste valor en caso de corte horizontal;
- Todas las dimensiones angulares son medidas en grados sexagesimales.

Las ecuaciones Ec. 6.4 proporcionan la diferencia en grados sexagesimales entre el ratio de la actividad considerada, y el más cercano de los extremos de los intervalos de validez para dicha actividad, en función del ratio del dominio que la genera mediante un corte. Esta diferencia oscilará entre  $0^\circ$  y  $45^\circ$  para actividades libres y entre  $0^\circ$  y  $90^\circ$  para actividades de orientación fija. Además, se propone emplear en todos los casos como penalización del incumplimiento una función de la forma:

$$f(I) = I^p \quad \text{Ec. 6.5}$$

donde:

- $I$  es  $I_{lib}$  en el caso de actividades de orientación libre y  $I_{fij}$  en el caso de actividades de orientación fija;
- $p$  es un entero positivo
- $p$  es un número natural perteneciente al intervalo  $[1, \infty[$ .

de tal manera que el incumplimiento aumente potencialmente al alejarse el ratio del dominio de partida de las zonas de validez. En aquellas zonas en las que el valor del incumplimiento es inferior a 1 dicha función hace disminuir la penalización, lo cual se ha considerado conveniente por la cercanía de esas zonas a ratios válidos.<sup>44</sup> En caso de permitir que  $I$  tome valores negativos y si  $p$  es par, la función potencial devolverá siempre valores positivos, por tanto, debe tomarse la precaución de volver a asignar valores negativos a los resultados de manera conveniente.

Como ejemplo de lo expuesto hasta el momento, supongamos un árbol de cortes básico formado por dos actividades  $A_1$  y  $A_2$  cuyas áreas son respectivamente 5 y 15 unidades, que deben formarse a partir del corte de un dominio  $A$ . Sean ambas actividades de orientación libre cuyos ratios deben permanecer en los intervalos  $[10^\circ, 20^\circ]$  en el caso de  $A_1$  y  $[40^\circ, 50^\circ]$  en el caso de  $A_2$ . La Figura 6.11 representa el incumplimiento formal de la actividad  $A_1$  en función del ratio de  $A$  para un corte horizontal, obtenido mediante la ecuación Ec. 6.5 en la que se ha dado a  $p$  el valor 1. Como puede observarse, existen dos intervalos de ratios de  $A$

<sup>44</sup> En caso de emplear radianes como unidad de medida angular, los valores obtenidos por las ecuaciones equivalentes a Ec. 6.4 vendrían dados en radianes, oscilando entre los 0 y los  $\pi/2$ . Gran parte de este rango de valores es inferior a la unidad, por lo que es necesario dar a la ecuación Ec. 6.5 una forma tal que considerase esta circunstancia.

que permiten a  $A_1$  cumplir las restricciones geométricas en caso de corte horizontal.

Si permitimos que el incumplimiento formal tome valores negativos, la gráfica resultante es la de la Figura 6.12, en la que los valores óptimos son los centros de los intervalos que permiten a  $A_1$  cumplir las restricciones geométricas.




Figura 6.11: Representación del incumplimiento formal de una actividad en función del ratio del dominio de partida.




Figura 6.12: Representación del incumplimiento formal de una actividad en función del ratio del dominio de partida con valores negativos permitidos.

En caso de emplear un valor de  $p$  más elevado en la ecuación Ec. 6.5, el incumplimiento aumentará potencialmente al alejarse el ratio del dominio de partida de las zonas de validez. Si en el caso que se está estudiando se diera a  $p$  el valor 2, el resultado sería el mostrado en la Figura 6.13.

La Figura 6.14 representa simultáneamente el incumplimiento formal de las actividades  $A_1$  y  $A_2$  generadas por el corte horizontal del dominio de partida en función del ratio del mismo. Como puede apreciarse existe un intervalo de ratios para el que ambas actividades cumplen sus requerimientos geométricos.




Figura 6.13: Representación del incumplimiento formal de una actividad en función del ratio del dominio de partida con carácter potencial ( $p=2$ ).




Figura 6.14: Representación del incumplimiento formal de dos actividades generadas por el corte de un dominio en función del ratio del dominio de partida.

Esta última circunstancia no tiene que producirse necesariamente; es posible que no exista un ratio del dominio inicial que permita que las dos actividades generadas tras el corte cumplan las restricciones geométricas. Como ejemplo, si suponemos que la actividad  $A_2$  tiene el mismo intervalo de validez de ratios que  $A_1$ , es decir  $[10^\circ, 20^\circ]$ , no existe ningún dominio inicial que permita, tras el corte horizontal, generar actividades válidas. Esto queda reflejado en la gráfica de la Figura 6.15.




Figura 6.15: Representación del incumplimiento formal de dos actividades generadas por el corte de un dominio en función del ratio del dominio de partida, para las que no existe un intervalo de validez común.

Las gráficas anteriores muestran el caso en el que el corte generador de las áreas asignadas a las actividades ha sido horizontal. La alternativa es que el corte se realice verticalmente, con lo que el valor del incumplimiento geométrico de las actividades en función del ratio del dominio de partida toma valores diferentes. La gráfica de la Figura 6.16 representa los incumplimientos formales para las dos actividades y en las dos posibilidades de corte.




Figura 6.16: Representación del incumplimiento formal de dos actividades generadas por un corte vertical u horizontal de un dominio en función del ratio del dominio de partida.

### 6.3.1.2 Potencial geométrico del árbol de cortes básico a partir de los incumplimientos formales de las actividades

En este punto se propone obtener el potencial geométrico del árbol de cortes básico a partir de los incumplimientos formales de las actividades que lo forman, independientemente

de que el corte se realice vertical u horizontalmente. Como primer paso se considera la suma de los incumplimientos de las dos actividades. Al definir de esta manera el potencial geométrico, un determinado árbol tendrá mayores posibilidades de generar distribuciones que respeten las restricciones geométricas cuanto menor sea su potencial<sup>45</sup>.




Figura 6.17: Representación de la suma de los incumplimientos formales de dos actividades generadas por un corte vertical y por un corte horizontal de un dominio en función del ratio del dominio de partida.

Resulta evidente que los incumplimientos formales de las actividades representados en la Figura 6.16 no pueden darse simultáneamente, por lo que dicha suma se realiza entre los incumplimientos de las actividades generados por el mismo tipo de corte, bien vertical, bien horizontal. En la Figura 6.17 se representan la suma de los incumplimientos de las dos actividades para un corte horizontal (H) y para un corte vertical (V).

A priori es imposible saber cuál es tipo de corte que generará las áreas de las actividades (vertical u horizontal), por lo que para valorar el potencial geométrico del árbol de cortes cabe plantearse tres posibilidades que han sido denominadas: estrategia acumulada, estrategia pesimista y estrategia optimista.

La **estrategia acumulada** consiste en definir el potencial geométrico del árbol de cortes básico como la suma de todos los incumplimientos posibles. Es decir, para un determinado ratio del dominio de partida, se define el potencial geométrico como la suma de los incumplimientos formales de las actividades para un corte vertical más la suma de los incumplimientos para un corte horizontal (Figura 6.19). El empleo de esta estrategia conlleva que el potencial geométrico será inferior para aquellos árboles que minimicen la suma de los incumplimientos de las actividades independientemente del tipo de corte que las genere.

La **estrategia pesimista** consiste en definir el potencial geométrico del árbol de cortes básico como la mayor de dos cantidades: la suma de los incumplimientos de las actividades en caso de corte horizontal y la suma de los incumplimientos en caso de corte vertical. Es

<sup>45</sup> De manera estricta, el potencial geométrico de un árbol de cortes así definido, mide la incapacidad del árbol de generar distribuciones válidas más que la capacidad de producirlas; es decir, un árbol con un elevado potencial geométrico será un mal candidato en la búsqueda de la distribución óptima. El proceso de búsqueda del árbol de cortes óptimo (o sub-óptimo) desde el punto de vista geométrico consistirá en localizar el árbol con menor potencial geométrico.

decir para cada ratio del dominio de partida el potencial geométrico será la suma de los incumplimientos de las actividades que resulte mayor, bien las verticales, bien las horizontales (Figura 6.18). El empleo de esta estrategia conlleva que el potencial geométrico será inferior para aquellos árboles que proporcionan un menor incumplimiento en el caso de que se produzca el más desfavorable de los cortes.




Figura 6.19: Potencial geométrico del árbol de cortes básico calculado mediante una estrategia acumulada.

La **estrategia optimista** consiste en definir el potencial geométrico del árbol de cortes básico como la menor de dos cantidades: la suma de los incumplimientos de las actividades en caso de corte horizontal y la suma de los incumplimientos en caso de corte vertical. Es decir, para cada ratio del dominio de partida el potencial geométrico será la suma de los incumplimientos de las actividades que resulte menor, bien las verticales, bien las horizontales (Figura 6.20). El empleo de esta estrategia conlleva que el potencial geométrico será inferior para aquellos árboles que proporcionan un menor incumplimiento en el caso de que se produzca el más favorable de los cortes.




Figura 6.18: Potencial geométrico del árbol de cortes básico calculado mediante una estrategia pesimista.

Las pruebas realizadas empleando los tres tipos de estrategias reseñados ofrecieron resultados que, en la mayor parte de los casos, eran favorables al empleo de la estrategia optimista frente a otras más conservadoras. Salvo en casos muy concretos, esta estrategia logró obtener árboles de corte que, posteriormente, dieron lugar a distribuciones con elevados grados de cumplimiento de las restricciones formales. Los árboles de cortes obtenidos en esta primera fase de optimización serán sometidos después, en la segunda fase, a un proceso de búsqueda de los cortes a realizar en cada subdominio para obtener la mejor distribución posible. Parece lógico pensar que el algoritmo empleado en esa segunda fase, será capaz de determinar si para cada subdominio es preferible un corte vertical o uno horizontal. Podría decirse que la estrategia optimista parte de la premisa de que posteriormente se escogerá el tipo de corte adecuado.




Figura 6.20: Potencial geométrico del árbol de cortes básico calculado mediante una estrategia optimista.

Así pues, esto confirma la **hipótesis 4** planteada en 6.2, y en adelante se empleará siempre la estrategia optimista, dado lo cual, el potencial geométrico del árbol de cortes básico queda definido como:

$$Pg_{ab}(\alpha) = \min(I_h, I_v) \quad \text{Ec. 6.6}$$

donde:

- $I_h$  es la suma de los incumplimientos formales de las actividades (libres o fijas) en caso de producirse un corte horizontal;
- $I_v$  es la suma de los incumplimientos formales de las actividades (libres o fijas) en caso de producirse un corte vertical;
- $\alpha$  es el ratio del dominio de partida;

### 6.3.2 Potencial geométrico de un árbol de cortes formado por un árbol básico y una actividad (árbol básico-actividad)

En los apartados precedentes se ha proporcionado un estimador de la capacidad de un


árbol de cortes formado por un único nodo del que penden dos actividades, para generar distribuciones que se ajusten a los requerimientos definidos para las áreas de las actividades. Se tratará ahora de determinar el potencial geométrico de un árbol, formado por un nodo del que pende una actividad y un árbol de cortes básico, tipo de árbol que denominaremos **básico-actividad** (Figura 6.21).

Para determinar el potencial geométrico de este tipo de árboles se propone emplear un procedimiento similar al sugerido en el caso de los árboles básicos. En primer lugar se calculará el potencial geométrico del árbol básico (en el ejemplo de la Figura 6.21 el formado por las actividades 1 y 2 y el nodo 4). Una vez determinado, podemos sustituir dicho árbol básico por una actividad cuya área sea la suma de las actividades de dicho árbol básico, y sus requerimientos geométricos vengan definidos por su potencial geométrico. De esta manera el árbol básico-actividad, se transforma en un árbol de cortes básico (Figura 6.22).

La actividad ficticia introducida tendrá un ratio geométrico que dependerá del ratio del dominio de partida, del tipo de corte que se haga a dicho dominio y del área de la actividad con la que comparte nodo, según se establece en las ecuaciones Ec. 6.1. Así pues, dado el ratio del dominio de partida y el tipo de corte, se obtiene el ratio de dicha actividad ficticia, y por lo tanto, el ratio del dominio de partida del árbol de cortes básico al que sustituye. Como su potencial geométrico es conocido para cualquier ratio, podemos determinarlo para ése en concreto mediante la ecuación Ec. 6.6.


Ahora es posible calcular el potencial geométrico del árbol básico-actividad como si de un árbol básico se tratara, con la diferencia de que el incumplimiento formal de la actividad ficticia introducida, será sustituido por el potencial geométrico del árbol de cortes básico al que sustituye. Lo que queda reflejado en la siguiente ecuación:

$$Pg_{aba}(\alpha) = \min(Pg_{ab}(\alpha_{ab\_h}) + la_h, Pg_{ab}(\alpha_{ab\_v}) + la_v)$$



Sub-árbol de cortes básico

Figura 6.21: Árbol de cortes formado por un árbol básico y una actividad.



Sub-árbol de cortes básico

Figura 6.22: Sustitución de un árbol básico por una actividad equivalente.



donde:

- $P_{g_{aba}}$  es el potencial geométrico del árbol básico-actividad;
- $P_{g_{ab}}$  es el potencial geométrico del árbol básico contenido en el árbol básico-actividad;
- $\alpha$  es el ratio del dominio de partida;
- $\alpha_{ab,h}$  es el ratio del dominio del árbol básico calculado mediante las ecuaciones Ec. 6.1 si el corte es horizontal;
- $\alpha_{ab,v}$  es el ratio del dominio del árbol básico calculado mediante las ecuaciones Ec. 6.1 si el corte es vertical;
- $la_h$  es el incumplimiento formal de la actividad no perteneciente al árbol básico en caso de producirse un corte horizontal del dominio de partida;
- $la_v$  es el incumplimiento formal de la actividad no perteneciente al árbol básico en caso de producirse un corte vertical del dominio de partida;

Como puede observarse se sigue manteniendo la estrategia optimista al elegir como potencial el del corte que produzca un valor más pequeño de los incumplimientos.

El empleo de la ecuación Ec. 6.7 puede ilustrarse mediante el siguiente ejemplo; sea un árbol de cortes básico-actividad formado por tres actividades y dos nodos con la estructura mostrada en la Figura 6.21.  $A_1$  y  $A_2$  son actividades cuyas áreas son respectivamente 5 y 15 unidades, de orientación libre, cuyos ratios deben permanecer en los intervalos  $[10^\circ, 20^\circ]$  en el caso de  $A_1$  y  $[40^\circ, 50^\circ]$  en el caso de  $A_2$ . Estas dos actividades pertenecen al árbol de cortes básico incluido en el árbol básico-actividad, y su potencial geométrico fue calculado en el ejemplo anterior. La actividad  $A_3$  tiene un área de 15 unidades, es de orientación libre y su ratio debe permanecer en el intervalo  $[30^\circ, 45^\circ]$ .

Dado que el potencial geométrico del subárbol de cortes básico que contiene a las actividades  $A_1$  y  $A_2$  en función de su dominio de partida ya ha sido calculado, es posible sustituir dicho subárbol por una actividad ficticia ( $A_f$ ) cuya área será la suma de las áreas de las actividades que contiene, es decir 20 unidades. Esto da lugar a una estructura de árbol de cortes básico (Figura 6.22).

Mediante las ecuaciones Ec. 6.1 se calcula el ratio de  $A_3$  y de  $A_f$  en función del ratio del dominio de partida para un corte vertical y para un corte horizontal, lo cuál queda reflejado en la Figura 6.23. Conocidos estos ratios es posible calcular el incumplimiento formal de la actividad  $A_3$  para cada tipo de corte, y el potencial geométrico del árbol de cortes básico representado por  $A_f$  también para cada tipo de corte, en función del ratio del dominio de partida. Los valores obtenidos se muestran en la Figura 6.24.




Figura 6.23: Ratio de las actividades de un árbol de cortes básico-actividad en función del ratio del dominio de partida.




Figura 6.24: Incumplimiento formal de la actividad y potencial geométrico de la actividad ficticia de un árbol de cortes básico, en función del ratio del dominio inicial, en caso de cortes vertical y horizontal.




Figura 6.25: Potencial geométrico de un árbol de cortes básico-actividad en función del ratio del dominio de partida.

Finalmente se calcula el potencial geométrico del árbol de cortes básico-actividad (Figura 6.25) mediante la ecuación Ec. 6.7. Para ello, se obtiene la suma del incumplimiento formal de  $A_3$  y el potencial geométrico de  $A_i$  tanto para el caso de corte vertical como horizontal, y se escoge el menor de los valores para cada ratio del dominio de partida.

Analizando el potencial geométrico del árbol de cortes básico-actividad de la citada figura, es posible afirmar que si el ratio del dominio de partida se encuentra dentro de alguno de los intervalos  $[22^\circ, 27^\circ]$ ,  $[33^\circ, 37^\circ]$ ,  $[53^\circ, 57^\circ]$  ó  $[63^\circ, 68^\circ]$ , es posible generar a partir de él, escogiendo adecuadamente el tipo de corte a realizar en cada subdominio, distribuciones en planta de las actividades que lo forman que cumplan con las restricciones geométricas impuestas.

Como ejemplo se ofrecen en la Figura 6.26<sup>46</sup> distribuciones que cumplen los requerimientos geométricos del problema. En la primera distribución el ratio del dominio inicial es  $26^\circ$  (aproximadamente un ratio alto-ancho de 0,5), que pertenece al primero de los intervalos de potencial nulo estimados mediante el potencial geométrico del árbol de cortes ( $[22^\circ, 27^\circ]$ ). En este caso, la actividad  $A_1$  posee un ratio de  $74,0^\circ$ . El ratio de validez de dicha actividad estaba fijado en el intervalo  $[10^\circ, 20^\circ]$ , pero dado que se trata de una actividad de orientación libre también se considera válido el intervalo  $[70^\circ, 80^\circ]$ . En la segunda distribución, el ratio del dominio inicial es  $36^\circ$ , perteneciente al segundo intervalo de potencial nulo de la Figura 6.25. En este caso la actividad  $A_3$  es válida al poseer orientación libre.




Figura 6.26: Distribuciones que cumplen los requerimientos geométricos con diferentes ratios del dominio inicial.

<sup>46</sup> Las distribuciones de la Figura 6.26 y de la Figura 6.27 no se han representado a escala.

Los intervalos de potencial nulo  $[53^\circ, 57^\circ]$  y  $[63^\circ, 68^\circ]$  son simétricos a los intervalos  $[22^\circ, 27^\circ]$ ,  $[33^\circ, 37^\circ]$  respecto del punto  $45^\circ$ . Así pues, y dado que las actividades son de orientación libre, basta con girar  $90^\circ$  las distribuciones de la Figura 6.26 para obtener otras que cumplen los requerimientos geométricos, y cuyos ratios de dominio principal pertenecen a aquellos intervalos (Figura 6.27).

En la gráfica de la Figura 6.25 puede observarse que el potencial geométrico del árbol de cortes para un dominio inicial de ratio  $45^\circ$  tiene un valor no nulo. Según la definición del potencial geométrico del árbol de cortes, esto significa que será imposible encontrar una distribución a partir de dicho árbol y con ese ratio del dominio, cuyas actividades cumplan las restricciones geométricas del problema planteado. Dado que para generar las distribuciones a partir de dicho árbol es necesario realizar dos cortes al dominio inicial, y dado que cada corte puede realizarse de cuatro formas diferentes, existen  $4^2$  posibles distribuciones. Todas estas posibilidades quedan reflejadas en la Figura 6.28 junto con los ratios resultantes de las actividades. Puede observarse que en ninguno de los casos se cumplen los requerimientos geométricos establecidos inicialmente para las áreas de las actividades, tal y como predecía su potencial geométrico no nulo.




Figura 6.27: Distribuciones que cumplen los requerimientos geométricos con diferentes ratios del dominio inicial.

Puede comprobarse que el incumplimiento formal de las actividades obtenidas para un ratio del dominio inicial de  $45^\circ$ , es inferior a los incumplimientos que se obtendrían para un ratio, por ejemplo, de  $10^\circ$ , que como puede observarse en la Figura 6.25 tiene un potencial geométrico mayor. Así pues, el potencial geométrico del árbol de cortes permite discriminar si es posible encontrar una solución geoméricamente aceptable para un determinado ratio,

y, para diversos ratios, clasificarlos en función de su capacidad de acercarse lo máximo posible a los requerimientos geométricos.

Actividad 1    
  Actividad 2    
  Actividad 3




Figura 6.28: Posibles distribuciones generadas por un árbol de 3 actividades y ratio de las áreas destinadas a cada una.

### 6.3.3 Potencial geométrico de un árbol de cortes formado por dos árboles básicos que penden de un nodo (árbol básico-básico)

En los apartados precedentes se ha proporcionado un estimador de la capacidad de un árbol de cortes básico y de un árbol de cortes básico-actividad, para generar distribuciones que se ajusten a los requerimientos definidos para las áreas de las actividades. Se tratará ahora de determinar el potencial geométrico de un árbol, formado por un nodo del que penden dos árboles de cortes básicos, tipo de árbol que denominaremos **básico-básico** (Figura 6.29).




Figura 6.29: Árbol de cortes formado por dos árboles básicos.

El procedimiento propuesto para tratar este tipo de árboles es similar al expuesto en el apartado precedente. En este caso se sustituirán los dos árboles de corte básicos por sendas actividades ficticias de área equivalente a las actividades del árbol al que sustituyen, y cuyo incumplimiento formal viene dado por el potencial geométrico de cada árbol básico sustituido. De esta manera el árbol básico-básico, se transforma en un árbol de cortes básico (Figura 6.30).

Las actividades ficticias introducidas tendrán un ratio geométrico que dependerá del ratio del dominio de partida, del tipo de corte que se haga a dicho dominio y del área de la actividad ficticia con la que comparte nodo, según se establece en las ecuaciones Ec. 6.1. Así pues, dado el ratio del dominio de partida y el tipo de corte, se obtiene el ratio de dichas actividades ficticias, y por lo tanto, el ratio del dominio de partida de los árboles de cortes básicos a los que sustituyen. Como los potenciales geométricos son conocidos para cualquier ratio, podemos determinarlo para ése en concreto mediante la ecuación Ec. 6.6.

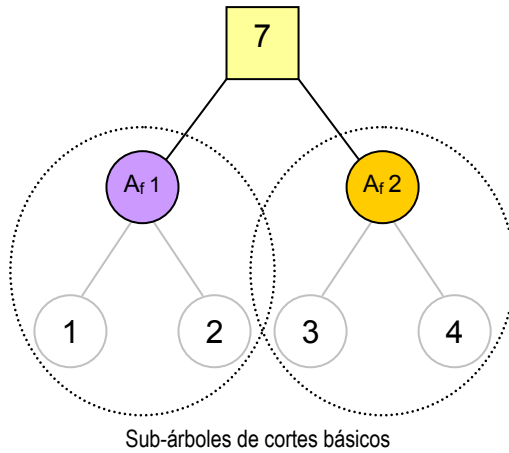


Figura 6.30: Sustitución de árboles básicos por actividades equivalentes

De esta manera, es posible calcular el potencial geométrico del árbol básico-básico como si de un árbol básico se tratara, con la diferencia de que los incumplimientos formales de las actividades ficticias introducidas, serán sustituidos por el potencial geométrico del árbol de cortes básico al que sustituyen. Lo que queda reflejado en la siguiente ecuación:

$$Pg_{abb}(\alpha) = \min(Pg_{ab1}(\alpha_{ab1\_h}) + Pg_{ab2}(\alpha_{ab2\_h}), Pg_{ab1}(\alpha_{ab1\_v}) + Pg_{ab2}(\alpha_{ab2\_v})) \quad Ec. 6.8$$

donde:

- $Pg_{abb}$  es el potencial del árbol básico-básico;
- $Pg_{ab\_1}$  y  $Pg_{ab\_2}$  son los potenciales de los árboles básicos contenidos en el árbol básico-básico;
- $\alpha$  es el ratio del dominio de partida;
- $\alpha_{ab1\_h}$  y  $\alpha_{ab2\_h}$  son los ratios de los dominios de los árboles básicos calculados mediante las ecuaciones Ec. 6.1 si el corte es horizontal;
- $\alpha_{ab1\_v}$  y  $\alpha_{ab2\_v}$  son los ratios de los dominios de los árboles básicos calculados mediante las ecuaciones Ec. 6.1 si el corte es vertical;

De nuevo se sigue manteniendo la estrategia optimista al elegir como potencial el del corte que produzca un valor más pequeño de los incumplimientos.

### 6.3.4 Generalización del cálculo del potencial geométrico a cualquier tipo de árbol de cortes

Una vez definida la forma de calcular el potencial geométrico de un árbol de cortes para tres casos particulares, se extenderá dicha definición a un árbol de cortes genérico. Todo árbol de cortes es de alguno de los tipos ya definidos (básico, básico-actividad, básico-

básico) o bien, es una composición de los mismos. Esto es, el cálculo del potencial geométrico de cualquier árbol de cortes, puede ser reducido al cálculo del árbol formado por el nodo raíz y dos actividades ficticias equivalentes a las dos ramas que penden de él (como si de un árbol básico se tratara).

Sea el árbol de cortes representado en la Figura 6.31 en la que se indican las áreas de las actividades (consideradas libres sin pérdida de generalidad) y los requerimientos geométricos de las mismas.

El proceso de cálculo del potencial geométrico de dicho árbol (Figura 6.32), comenzaría por el cálculo del potencial geométrico de los tres subárboles básicos formados por las actividades que penden de los nodos 8, 9 y 12. Conocido dichos potenciales geométricos es posible sustituir dichos subárboles por actividades ficticias ( $A_{f8}$ ,  $A_{f9}$ ,  $A_{f12}$ ), con área equivalente a la suma de las áreas de las actividades sustituidas, siendo sus incumplimientos formales en adelante, el potencial geométrico de cada subárbol.

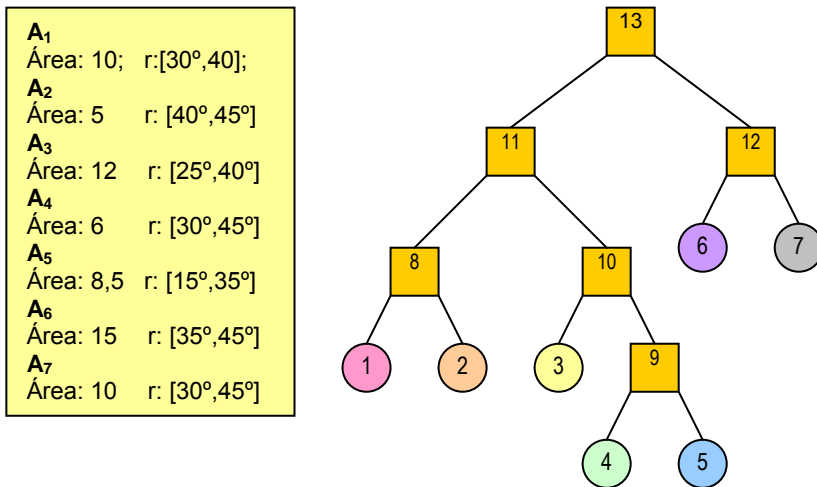


Figura 6.31: Árbol de cortes de 7 actividades y datos de las mismas.

Tras esta sustitución, el nodo 10 y las actividades 3 y  $A_{f9}$  forman un subárbol básico-actividad que puede ser tratado como se vio en el apartado 6.3.2, sustituyéndolo por una actividad ficticia ( $A_{f10}$ ) equivalente a dicho subárbol. Con este cambio, el nodo 11 y las actividades  $A_{f8}$  y  $A_{f10}$  forman un subárbol básico-básico. Actuando como se indica en el apartado 6.3.3 es posible sustituirlo por la actividad ficticia  $A_{f11}$  equivalente, dando por resultado un árbol básico-básico (nodo 13 y actividades  $A_{f11}$  y  $A_{f12}$ ).

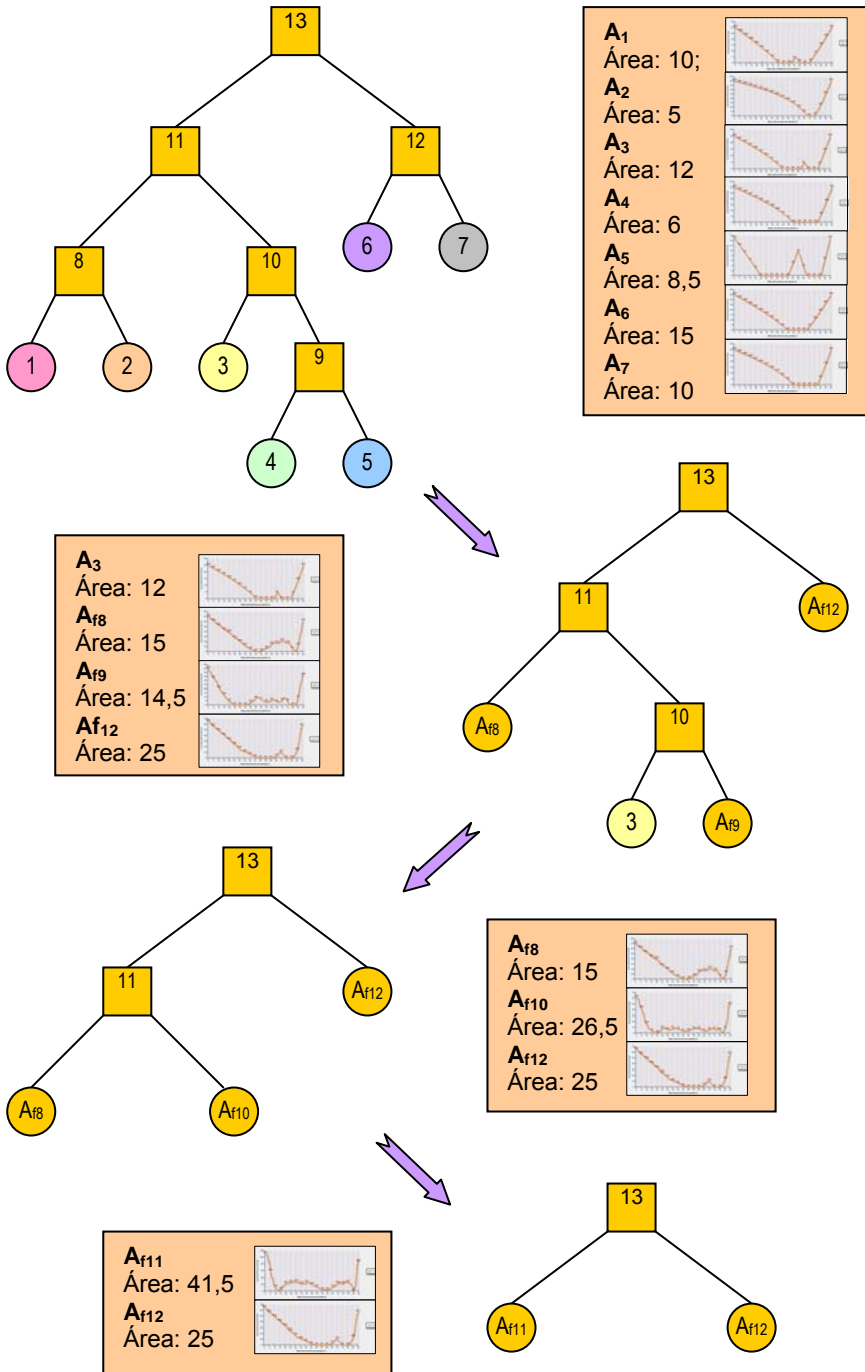


Figura 6.32: Proceso de cálculo del potencial geométrico de un árbol de cortes genérico.



En la Figura 6.33 se han representado los incumplimientos formales de las 7 actividades en función del ratio del subdominio a partir del cuál son generadas. En este caso no se han permitido incumplimientos formales de valor negativo y el valor de  $p$  es 1 (Ec. 6.5).

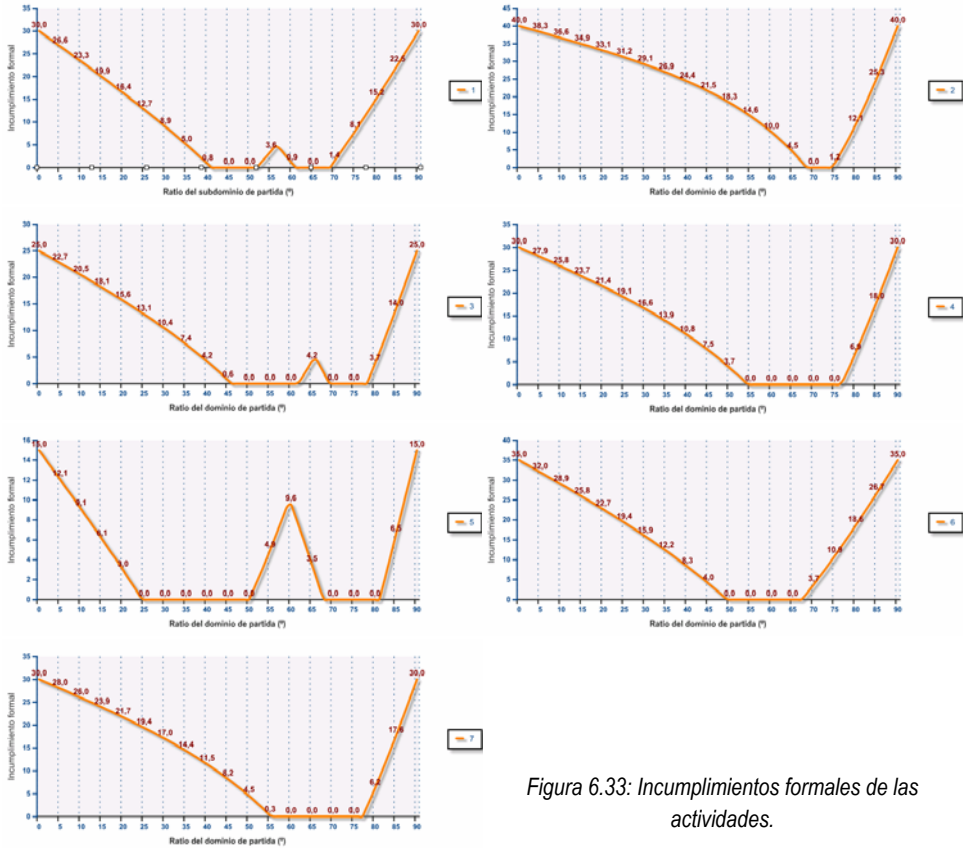
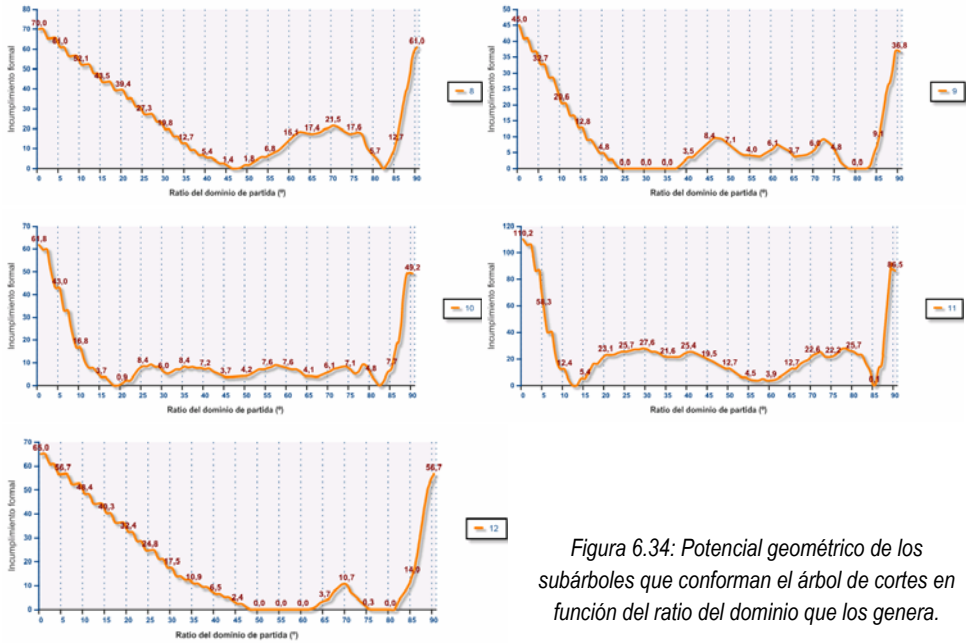



Figura 6.33: Incumplimientos formales de las actividades.

Los potenciales geométricos calculados para cada uno de los subárboles de cortes que conforman el árbol han sido representados en la Figura 6.34. Como se indicó anteriormente, el potencial geométrico de un árbol depende del ratio del dominio que lo genera; éste a su vez depende del ratio del dominio inmediatamente superior y del área de la actividad (o subárbol) con la que comparte nodo según las ecuaciones Ec. 6.1. En la Figura 6.34 el potencial geométrico de cada subárbol está representado en función del ratio del dominio superior.

Por último, la Figura 6.35 representa el potencial geométrico de todo el árbol de cortes. En este caso la representación se realiza en función del ratio del dominio de la planta, dado que no existe un dominio de nivel superior. Como puede comprobarse en dicha figura, el potencial geométrico es simétrico respecto del ratio 45°, lo cuál resulta lógico dado que todas las actividades son de orientación libre. Así, una determinada distribución generada por dicho árbol sobre un dominio de ratio  $\alpha$ , deberá poseer el mismo grado de cumplimiento de los requerimientos geométricos que otra distribución consistente en girar 90° la anterior (cuyo ratio será  $90-\alpha$ ).



El potencial geométrico obtenido indica que dadas las condiciones del problema planteado, no será posible encontrar una distribución a partir de dicho árbol que cumpla con los requerimientos geométricos exigidos a las actividades. Por otra parte, puede observarse que ratios del dominio de la planta comprendidos entre los 30° y los 35° (o de forma equivalente entre los 55° y los 60°), minimizarán el incumplimiento geométrico. Así pues, en aquellos casos en los que dicho dominio inicial no esté previamente fijado (construcción de una nueva planta), será posible determinar la forma más recomendable desde el punto de



vista geométrico<sup>47</sup>.

#### **6.4. Definición de una función evaluadora para la primera fase de LAYAGEN G: optimización del árbol de cortes**

Se definirá en este apartado la función evaluadora de la calidad de los árboles de cortes, como formas de estructurar las actividades potencialmente capaces de generar distribuciones en planta que cumplan los requerimientos del problema planteado. Es necesario que la función definida contemple los diferentes criterios adoptados en la medición de dicha calidad.

Como ya se indicó, Santamarina [Santamarina, 95] propone una función objetivo de naturaleza multicriterio que denomina potencial del árbol de cortes, como medida de la adaptación de una especie (árbol) al medio en que se desenvuelve. Esta función trata de localizar el árbol de cortes de máximo potencial, es decir, hallar el árbol de menor coste relacional. Dicha función tiene la forma:

$$P(AC) = \sum_{i=1}^n \sum_{j=1}^n P(ij) \cdot \left[ \pm \sum_{u=1}^k \alpha_u \cdot f_{u,ij} \pm \sum_{v=1}^{k'} \beta_v \cdot t_{v,ij} \right] \quad \text{Ec. 6.9}$$

donde:

- **P(AC)** es el potencial del árbol de cortes;
- **$\alpha_u$**  y  **$\beta_v$**  son los coeficientes de ponderación representativos de la importancia relativa entre factores de índole cuantitativa y cualitativa respectivamente;
- **$f_{u,ij}$**  es el valor de la intensidad relacional [Hospitaler et al., 86] existente entre las actividades **i** y **j**, bajo el criterio cuantitativo **u**-ésimo ;
- **$t_{v,ij}$**  es el valor de la intensidad relacional existente entre las actividades **i** y **j**, bajo el criterio cualitativo **v**-ésimo ;
- **k** es el número de criterios cuantitativos contemplado;
- **k'** es el número de criterios cualitativos contemplado;
- **P(ij)** es el potencial de adyacencia entre dos actividades **i** y **j** del árbol de cortes;
- **$\pm$**  es el símbolo **+** ó **-** que se escogerá en función del significado del indicador utilizado para estimar la intensidad relacional;

Esta función es un estimador que indica la capacidad de un árbol de cortes para permitir la adyacencia de las actividades que así lo requieran en función de diferentes criterios medidos cualitativa o cuantitativamente (flujo de materiales entre actividades, seguridad, molestias debidas a ruidos, olores, vibraciones...). El potencial de adyacencia entre dos actividades **i** y **j** del árbol de cortes se calcula mediante la expresión **P(ij)=P(i)\*P(j)**. Esta ecuación desarrollada toma la forma <sup>48</sup>:

<sup>47</sup> Esto no implica que dicha forma sea necesariamente la mejor desde el punto de vista de otros factores (por ejemplo el flujo de materiales entre las actividades).

<sup>48</sup> La manera de obtener esta expresión ha sido tratada en el capítulo precedente.

$$P(ij) = \left(\frac{3}{4}\right)^{s+s'-2} \quad \text{Ec. 6.10}$$

donde:

- $P(ij)$  es el potencial de adyacencia entre dos actividades  $i$  y  $j$ ;
- $s$  es el número de nodos que hay que recorrer a lo largo de las ramas del árbol en dirección ascendente para, partiendo de la actividad  $i$ , encontrar el primer nodo común con el mismo recorrido realizado partiendo desde la actividad  $j$ .
- $s'$  es el número de nodos que hay que recorrer a lo largo de las ramas del árbol en dirección ascendente para, partiendo de la actividad  $j$ , encontrar el primer nodo común con el mismo recorrido realizado partiendo desde la actividad  $i$ .

La capacidad de dos actividades de mantenerse adyacentes en las diferentes distribuciones generadas a partir del árbol de cortes es función de la profundidad relativa de las mismas en dicho árbol, y en el trabajo de Santamarina, este estimador ha demostrado su aptitud a la hora de medir dicha capacidad.

Así pues, la función evaluadora que se propone en el presente trabajo para la fase de optimización del árbol de cortes, combinará el potencial del árbol de cortes propuesto por Santamarina, con el potencial geométrico del árbol de cortes descrito en el apartado 6.3 en una función aditiva ponderada. Esta combinación permitirá obtener un estimador de la capacidad de un árbol de cortes para mantener adyacentes las actividades que lo requieran, respetando simultáneamente las restricciones geométricas de las actividades.

#### 6.4.1 Potencial del árbol de cortes

Para distinguir el potencial del árbol de cortes definido por Santamarina del que se propone a continuación, a partir de este punto se denominará **potencial relacional del árbol de cortes** al primero (Ec. 6.10), **potencial geométrico del árbol de cortes** al definido en el apartado 6.3, y **potencial del árbol de cortes** a la composición de los anteriores.

El potencial relacional del árbol de cortes toma un valor fijo para cada árbol de cortes. El potencial geométrico, sin embargo, es una función del ratio del dominio de ubicación de la planta. Si este ratio está fijado previamente, el potencial geométrico será el valor de dicha función para ese ratio. Puede ser conveniente no fijar a priori el ratio cuando la planta sea de nueva construcción, situación en la que se definirá un intervalo en el cuál debe permanecer el ratio. Se propone que, en estos casos, el potencial geométrico del árbol de cortes tome el valor mínimo de la función en el intervalo de ratios definido. Es decir, si el ratio del dominio de la planta es fijo e igual a  $\alpha$  el potencial geométrico del árbol de cortes será  $P_{gac} = P_{gac}(\alpha)$ . Si el ratio no es fijo y debe permanecer en el intervalo  $[\alpha_{min}, \alpha_{max}]$ , el potencial geométrico será:

$$P_{gac} = \min(P_{gac}(\alpha)) ; \alpha_{min} \geq \alpha \geq \alpha_{max} \quad \text{Ec. 6.11}$$




Figura 6.36: Potencial geométrico del árbol de cortes para ratio del dominio de ubicación de la planta no fijado.

La situación de ratio fijo es un caso particular de ratio no fijado en el que  $\alpha_{\min} = \alpha = \alpha_{\max}$ . Así pues, y por claridad en la notación, a partir de este momento el potencial geométrico del árbol de cortes será el valor obtenido mediante la expresión Ec. 6.11.

Ya se ha dicho que el potencial del árbol de cortes será una función aditiva ponderada de los dos tipos de potenciales definidos, el relacional y el geométrico. Se propone inicialmente la siguiente expresión <sup>49</sup>:

$$P_{ac} = C_g \cdot P_{gac} + C_r \cdot \frac{1}{1 + P_{rac}} \quad \text{Ec. 6.12}$$

donde:

- $P_{ac}$  es el potencial del árbol de cortes;
- $P_{gac}$  es el potencial geométrico del árbol de cortes tal y como se define en Ec. 6.11;
- $P_{rac}$  es el potencial relacional del árbol de cortes tal y como se define en Ec. 6.10;
- $C_g$  y  $C_r$  son los coeficientes de ponderación representativos de la importancia relativa entre el criterio geométrico y relacional respectivamente;

Al definir de esta manera el potencial de árbol de cortes, el proceso de optimización en la primera fase del algoritmo consistirá en localizar el árbol de cortes de menor potencial. El potencial relacional fue definido por Santamarina de manera inversa a la aquí presentada para el potencial geométrico, es decir, los árboles de cortes más adaptados tienen un potencial relacional mayor, así pues, se ha introducido en el denominador de uno de los términos de la función. De esta manera, minimizar el potencial del árbol de cortes significará minimizar el potencial geométrico y maximizar el relacional. Para evitar en dicho

<sup>49</sup> Aunque hasta el momento, y para una mejor comprensión de los conceptos expuestos, se ha empleado el grado sexagesimal como unidad de medida del incumplimiento geométrico y del potencial geométrico del árbol de cortes, es conveniente recordar que las unidades empleadas en la implementación del algoritmo y en los experimentos realizados ha sido el radián. Esto resulta de especial importancia a la hora de escoger los coeficientes de ponderación de la Ec. 6.12.

denominador términos menores que la unidad se suma 1 al potencial relacional.

Como ejemplo se retomará el del apartado 6.3.4. Sea el árbol de cortes propuesto en dicho ejemplo (Figura 6.37), y un ratio de la planta fijado en 45°. Sean los flujos de material por unidad de tiempo entre las actividades los reflejados en la Tabla 6.1.

Como ya se calculó en dicho ejemplo (Figura 6.35), el potencial geométrico del árbol de cortes para un ratio del dominio de ubicación de la planta de 45° es 0,382 radianes (21,9° aproximadamente). Para el obtener el potencial relacional, se calcularán los potenciales de adyacencia de todos los pares de actividades mediante la Ec. 6.10, resultados que se exponen en la Tabla 6.2. Haciendo uso de estos valores, mediante la aplicación la Ec. 6.9 se obtiene un valor para el potencial relacional de 24,27. Dando a ambos coeficientes de ponderación **Cg** y **Cr** el valor 1000, la Ec. 6.12 determina un potencial del árbol de cortes de 419,57 unidades.

Suponiendo ahora que el ratio de la planta no esta fijado a priori, y que se desea que su coeficiente alto/ancho oscile entre 0,4 y 0,8 (es decir, entre los 22° y los 39° aproximadamente), el potencial geométrico del árbol pasará a ser 0,0666 (3,82°), que corresponden a un ratio del dominio de la planta de 31° (valor mínimo en ese intervalo como puede apreciarse en la Figura 6.36).

El valor del potencial relacional no depende directamente del ratio por lo que permanecerá su valor de 24,27 unidades calculado anteriormente. Si se mantienen los valores de **Cg** y **Cr**, el nuevo potencial del árbol de cortes será 106,17. Este valor es inferior al anterior debido a que la capacidad del árbol de cortes para generar distribuciones geoméricamente adecuadas, es mayor si el ratio de la planta se acerca a 31°. Así pues, en los casos en los que la forma del dominio




Figura 6.37: Árbol de cortes de 7 actividades.

	A1	A2	A3	A4	A5	A6	A7
A1	•	1	1	3	2	3	
A2		•	2				5
A3	1		•	1		12	
A4			2	•		1	2
A5	2				•		1
A6	2					•	2
A7				4		2	•

Tabla 6.1: Flujo de materiales entre actividades por unidad de tiempo.

	A1	A2	A3	A4	A5	A6	A7
A1	•	1	0,56	0,42	0,42	0,42	0,42
A2	1	•	0,56	0,42	0,42	0,42	0,42
A3	0,56	0,56	•	0,75	0,75	0,42	0,42
A4	0,42	0,42	0,75	•	1	0,32	0,32
A5	0,42	0,42	0,75	1	•	0,32	0,32
A6	0,42	0,42	0,42	0,32	0,32	•	1
A7	0,42	0,56	0,42	0,32	0,32	1	•

Tabla 6.2: Potenciales de adyacencia de las actividades.

no esté predefinida, el potencial geométrico del árbol sirve de referencia en la búsqueda de la forma más conveniente.

En el algoritmo planteado en el presente trabajo, la primera fase, la de búsqueda del árbol de cortes óptimo, concluirá proponiendo el mejor de los árboles de corte encontrado para su explotación en la segunda fase. Si el ratio del dominio de ubicación de la planta no esta fijado, como resultado de la primera fase se obtendrá además, el ratio óptimo de la planta para dicho árbol.

## 6.5. Estructura general del algoritmo LAYAGEN G

Ya se ha indicado que LAYAGEN G tendrá una estructura bifásica. En la primera de las fases se determinará el árbol de cortes con mayor potencial para generar distribuciones que cumplan los requerimientos geométricos y, por otra parte, que resulten óptimos desde el punto de vista de los diferentes criterios empleados en la evaluación. En la segunda fase se tratará de localizar la mejor de las distribuciones que es posible obtener a partir de dicho árbol (Figura 6.38).

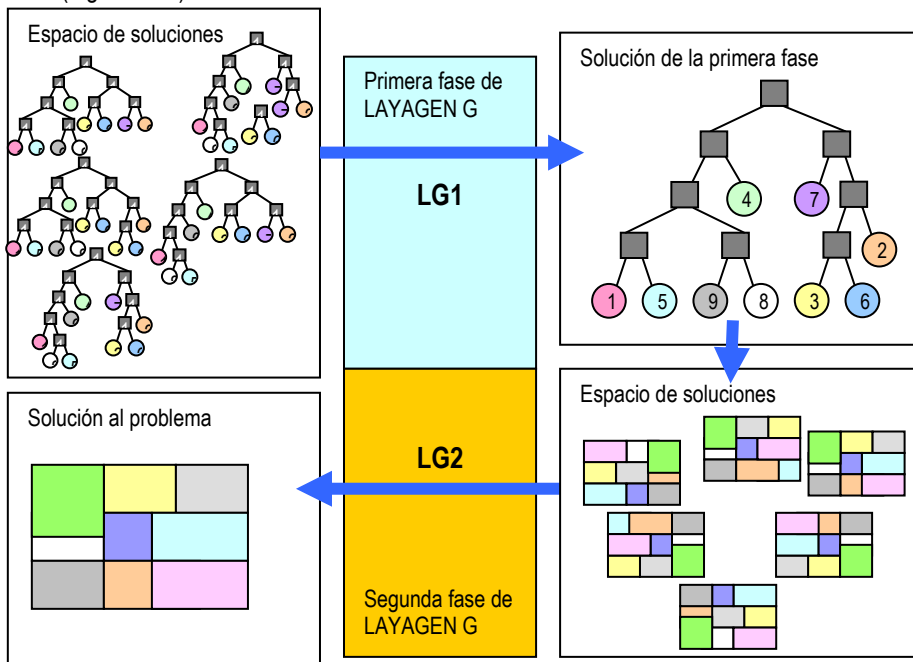


Figura 6.38: Estructura bifásica de LAYAGEN G.

La primera de las fases puede asimilarse, tal como hace Santamarina [Santamarina, 95], a la búsqueda de la especie más adecuada para subsistir en un determinado hábitat, estableciendo una analogía entre árbol de cortes y especie. Una vez determinada la especie se trata de localizar al individuo de dicha clase que mejor se adapte al entorno en la segunda fase. En este caso la analogía se establece entre distribuciones e individuos.

La primera fase de la metodología (LG1) es una variación de la primera fase del algoritmo LAYAGEN de Santamarina, modificando substancialmente el flujo del algoritmo, los operadores genéticos y la función evaluadora, introduciendo fases de intensificación local de la búsqueda y empleando estrategias elitistas. La segunda fase (LG2) es la ya definida por Tam [Tam, 92c] y empleada por Santamarina, en la que se han introducido modificaciones que pretenden mejorar el rendimiento del algoritmo y adaptarlo a las particularidades introducidas en la primera fase.

En definitiva, el algoritmo presentado, LAYAGEN G, es una evolución de LAYAGEN dirigida a obtener un procedimiento de resolución del problema de distribución en planta que permita poseer un elevado control geométrico de las soluciones, al mismo tiempo que mejora su capacidad de localizar soluciones de bajo coste relacional.

## **6.6. La primera fase de LAYAGEN G (LG1)**

La primera fase de LAYAGEN G (que se denominará en adelante LG1) comienza generando una población inicial de  $n$  individuos. Cada una de las cadenas es evaluada mediante el Potencial del Árbol de Cortes al que representa, obteniendo así una medida de su aptitud para sobrevivir y reproducirse.

En LG1 se define la probabilidad de cruce ( $P_c$ ), como la proporción de la siguiente generación que estará constituida por individuos que son el resultado del cruce de dos miembros de la generación anterior. Así pues, si  $P_c=0,8$  el 80% de la nueva generación será generado mediante cruce. Para ello se seleccionan  $0,5 \cdot n \cdot P_c$  parejas de individuos de la población. Cada pareja se cruza dando lugar a dos nuevos individuos que pasan directamente a la nueva generación.

Se ha escogido emplear una estrategia elitista en LG1 que será justificada en apartados posteriores. Por ello, una cierta cantidad de individuos ( $I_{e1}$ ) se conserva de generación en generación mediante un mecanismo que será explicado ulteriormente. El resto de la nueva generación,  $n(1-P_c)-I_{e1}$  individuos, se selecciona de la población estando incluidos en el proceso selectivo los individuos que han participado en la reproducción. La selección tanto de los individuos reproductores como de los supervivientes se realiza mediante muestreo estocástico conservador. La élite se selecciona de manera directa, no es sometida a un proceso aleatorio de selección.

Sobre los individuos que conformarán la nueva generación actúa el operador mutación. En LG1 la probabilidad de mutación ( $P_m$ ) se entiende de una manera particular.  $P_m$  se define como la proporción de individuos que se verá afectada por la mutación. Así pues, si  $P_m=0,5$ , el 50% de la población recién creada se someterá al operador mutación. Los individuos que mutarán se seleccionan de manera totalmente aleatoria de entre los obtenidos en los procesos anteriores: los supervivientes, los descendientes y la élite.

Habitualmente la probabilidad de mutación se define como la probabilidad de que cada gen de una cadena mute, por lo que los valores típicos de este parámetro suelen ser inferiores a 0,1. Dada la definición que se da en LG1 los valores de  $P_m$  serán más elevados, oscilando entre 0,5 y 0,8.



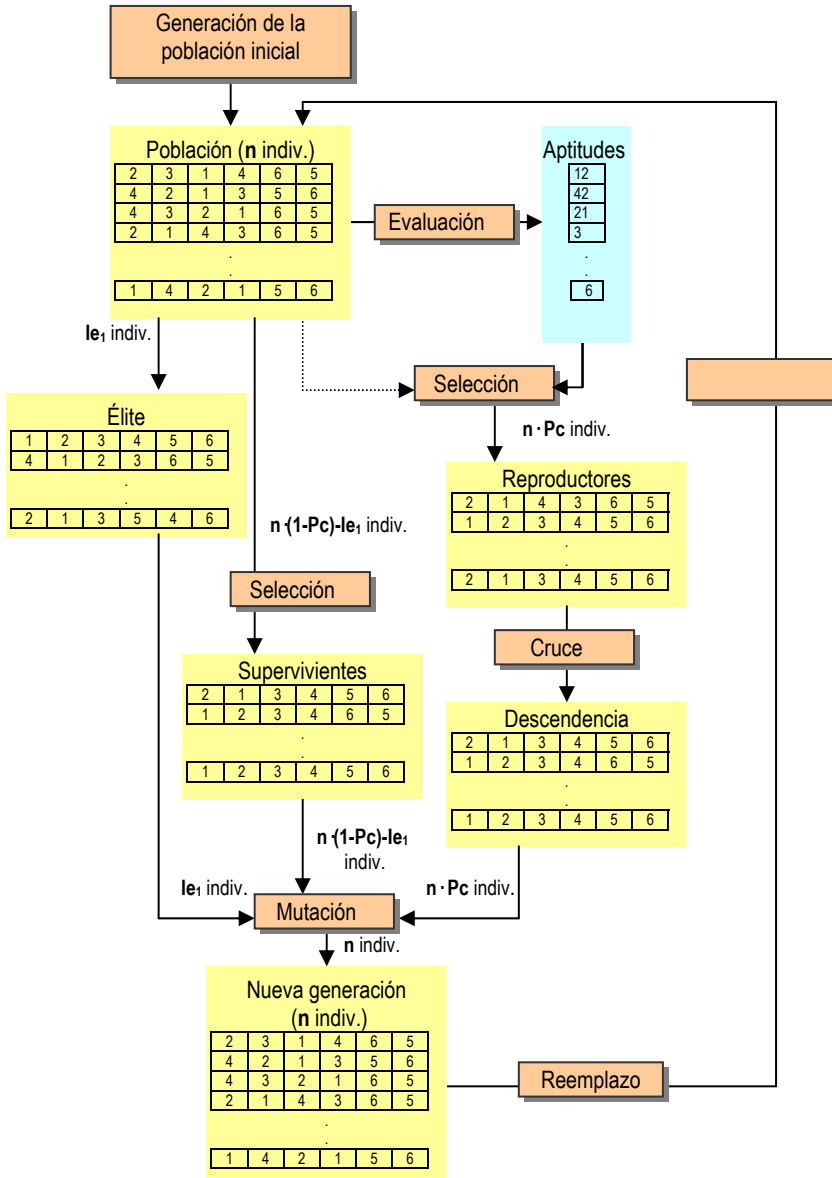


Figura 6.39: Diagrama general del flujo de LG1.

La nueva generación así creada será de nuevo evaluada y sometida a los operadores genéticos dando lugar a otra generación. Este procedimiento se repite hasta que se realice un número prefijado de iteraciones ( $N_g$ ). Sin embargo, cuando se dan ciertas condiciones en

el grado de convergencia de la población, el algoritmo puede entrar en una fase de intensificación local de la búsqueda que pretende la exploración exhaustiva de una zona determinada del espacio de soluciones.

Esta descripción genérica de LG1 se completa detallando en los siguientes apartados: la forma de codificar las soluciones, la forma de generar la población inicial de árboles de cortes, la forma de evaluar las soluciones, los operadores genéticos y la estrategia elitista empleada, los mecanismos de intensificación de la búsqueda implementados, y la ejecución paralela en una red de ordenadores del algoritmo.

### 6.6.1 Codificación de los árboles de cortes

La codificación/descodificación de los árboles de cortes en cadenas de longitud finita se lleva a cabo con el mecanismo propuesto por Santamarina y que ha sido expuesto en el capítulo anterior. Esta codificación no es binaria y la cadena resultante puede parecer un tanto difícil de interpretar, sin embargo, en comparación con otras formas de codificación basadas en la propuesta de Tam [Tam et al., 98], necesita de un conjunto de reglas constructivas menor, las cadenas resultan más compactas, y con una correcta adecuación de los operadores genéticos la probabilidad de obtener individuos no factibles a raíz de su aplicación puede ser reducida.

El mecanismo de codificación/descodificación se basa en el procedimiento empleado para la generación de los árboles de corte mediante la formación de clusters y puede ser consultado en el capítulo precedente. Sin embargo, por lo importante de su adecuada comprensión se expone de manera sucinta en este punto.

Para  $n$  actividades numeradas desde 1 hasta  $n$  la generación de los árboles comienza agrupando dos actividades seleccionadas aleatoriamente. A este cluster se le denominará  $n+1$ . Los números que representan las actividades seleccionadas conforman los dos primeros elementos de la cadena que representa al árbol (ver Figura 6.40).

Se repite el proceso de selección aleatoria para la formación de un nuevo cluster. Se podrán seleccionar dos elementos del conjunto formado por las actividades que no pertenecen a ningún cluster y los cluster ya formados. Los dos números que representan las actividades o clusters seleccionados se añaden a la cadena representativa del árbol. Este procedimiento se repite hasta que no quede ningún elemento por seleccionar.

Las cadenas así formadas tendrán una longitud de  $2n-2$  elementos (genes), de los cuales  $n-2$  son valores mayores que  $n$  y representan clusters o agrupación de elementos. Los genes pueden tomar valores en el conjunto de alelos  $\theta=\{1,2,3,\dots,2n-2\}$ .




Figura 6.40: Generación de árboles de cortes y codificación en cadenas en LAYAGEN.

En el proceso de descodificación de las cadenas se consideran los elementos o genes que la forman por parejas (Figura 6.41). El número de parejas será  $n-2$ , tantas como agrupaciones realizadas o como nodos conformarán el árbol de cortes. El primer par de genes representan las actividades contenidas en el primer cluster (el  $n+1$ ) y que penderán de un mismo nodo, el segundo par de genes representan las actividades contenidas en el cluster ( $n+2$ ) y así sucesivamente. El primer elemento de cada par penderá a la izquierda del nodo correspondiente.

Cuando uno de los elementos de un par es mayor que  $n$ , indica que de ese nodo pende las actividades de otro par previamente formado. Si los dos elementos son mayores que  $n$ , de dicho nodo penden dos nodos ya formados con sus respectivas actividades.

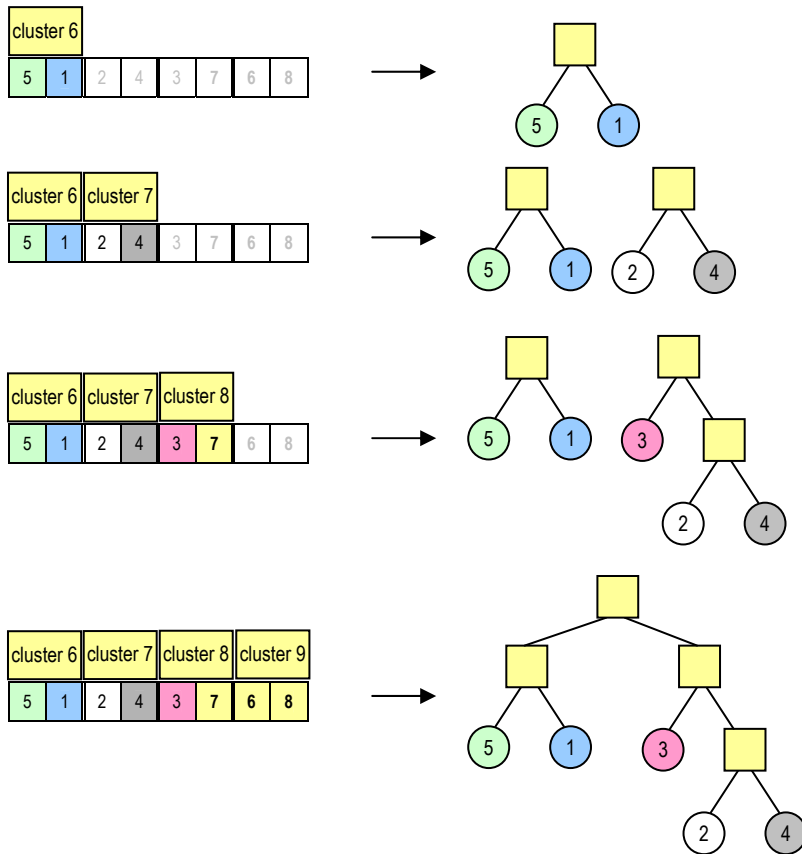


Figura 6.41: Decodificación de cromosomas en LAYAGEN para obtener los árboles de corte que representan.

El último de los clusters, el denotado como  $2 \cdot n - 1$  (cluster 9 en la figura), no aparece explícitamente en la cadena como elemento dado que proporcionaría una información innecesaria. Evidentemente el último nodo/cluster debe ser el nodo raíz.

Esta codificación cumple tres de las cinco propiedades recomendables para un sistema de simbolización [Pérez, 04]:

- **Completitud:** cualquier árbol de cortes puede ser representado mediante esta codificación.
- **Uniformidad:** todas las soluciones deben poder ser representadas por un número igual de codificaciones, evitando que unas lo estén más o menos que otras; de hecho, en la codificación empleada existe una relación biunívoca entre el espacio de las cadenas y el de los árboles de corte [Santamarina, 95].

- **Sencillez:** La codificación y decodificación de las soluciones es un mecanismo relativamente sencillo.

Hay dos propiedades recomendables que no son cumplidas por el sistema de codificación empleado:

- **Coherencia:** un sistema de codificación con esta propiedad hace corresponder a cualquier cadena que se pueda componer una solución.
- **Localidad:** Debe existir proporcionalidad entre las variaciones de las codificaciones y las variaciones de los individuos representados; si se producen pequeños cambios en las cadenas, deben producirse pequeños cambios en las soluciones, asimismo, grandes cambios en las cadenas deben dar lugar a importantes cambios en las soluciones.

En la codificación empleada existen cadenas que representan individuos no factibles, por ello no posee la propiedad de **coherencia**. Por ejemplo, en un cromosoma para  $n$  actividades, para que un elemento mayor que  $n$  pueda aparecer en la cadena el cluster que representa debe estar situado en posiciones precedentes. Concretamente, un elemento  $x > n$  no puede aparecer en la cadena en posiciones inferiores a  $2 \cdot (x-n)+1$ , dado que esto implica que se debe colocar en el árbol de cortes un nodo que del que aún no se han determinado sus ramas. En la Figura 6.42 se representa un cromosoma en la que el cluster 8 ocupa los genes quinto y sexto, sin embargo, el número 8 aparece ya en el tercer gen. Es decir, en la decodificación habría que situar en el árbol un cluster aún no formado. Por otra parte, en la cadena de la figura el cluster 8 contiene al 7 y el 7 contiene al 8, situación que genera un árbol disgregado y sin sentido.




Figura 6.42: Cromosoma que representa un individuo no factible.

El problema de la **incoherencia** no es atípico, la mayor parte de las codificaciones empleadas en la bibliografía son incoherentes. El empleo de códigos no binarios que pretenden representar estructuras complejas como las de un árbol de cortes provoca que la ordenación de los cromosomas deba cumplir ciertas reglas (como las ya vistas para la codificación de Santamarina o las *Gambler's ruin* en otras codificaciones [Sedgewick et al., 96]), si éstas no se cumplen se da lugar a estructuras incoherentes que no representan individuos factibles. Las soluciones a este problema ya se expusieron en capítulos precedentes: el descarte o penalización, la reparación o la codificación cerrada. La forma de afrontar el problema en la metodología propuesta se explicara cuando se trate la manera de generar la población inicial y el mecanismo de actuación de los operadores genéticos.

La propiedad de **localidad** no se mantiene en la codificación, puesto que cambios de igual entidad en las cadenas pueden representar cambios más o menos importantes en los individuos dependiendo de las posiciones de la cadena que se modifiquen y del contenido de

dichos genes. En general, cambios producidos en los primeros genes del cromosoma repercutirán en el individuo que representan en menor medida que cambios en los últimos genes en los que el cambio puede ser radical (acantilados de Hamming [Schaffer et al., 89]). Esto es así puesto que los últimos genes del cromosoma representan nodos o actividades situados en el árbol en posiciones más cercanas al nodo raíz. En la Figura 6.43 se muestra un árbol de cortes de 5 actividades. En el caso a) se han modificado los genes cuarto y séptimo de la cadena, lo que ha provocado un cambio substancial de la estructura del árbol. En el caso b) los genes afectados son el primero y el segundo, y como consecuencia el árbol mantiene su estructura intercambiando sólo la posición de dos actividades pendientes de un mismo nodo.




Figura 6.43: Falta de localidad en la codificación de los árboles de corte.

El valor de los alelos objeto de modificación también determinará la repercusión que el cambio tendrá sobre el individuo. Si el gen modificado posee un alelo de valor menor que  $n$  (número de actividades), el cambio será de menor cuantía que si el valor del alelo es mayor que  $n$ , dado que en este caso el gen representa un nodo del árbol y se puede ver afectada toda una rama por el cambio.

El problema de falta de localidad afecta al funcionamiento del algoritmo fundamentalmente durante la aplicación de los operadores genéticos, donde la asimetría en la consecuencia de los cambios puede sesgar la deseable aleatoriedad en determinados

aspectos de los operadores. Este tema será de nuevo abordado durante la definición de los operadores genéticos, donde se establecerá la manera de aprovechar ésta falta de localidad como medio para controlar la convergencia de la población.

### 6.6.2 Formación de la población inicial de soluciones

El procedimiento para formar la población inicial es el mismo que el empleado en LAYAGEN. El procedimiento es aleatorio pero estableciendo un proceso de generación de soluciones que produzca únicamente individuos factibles.

Sea un problema de  $n_a$  actividades para el que se quiere crear una población inicial de  $n$  individuos. Se crea una lista de clusters que en principio contiene las  $n_a$  actividades que componen el problema. Se seleccionan aleatoriamente dos ítems de la lista y se fusionan en un cluster (el  $n_a+1$ ), colocando las actividades implicadas en los dos primeros genes de la cadena. El nuevo cluster formado se añade a la lista de clusters y de ésta se eliminan las actividades fusionadas. Se seleccionan dos nuevos ítems de la lista, que incluye ahora las actividades no fusionadas todavía y los clusters ya formados. Los dos ítems elegidos se colocan en el tercer y cuarto gen de la cadena, se eliminan de la lista y se introduce el nuevo cluster formado (el  $n_a+2$ ). Este procedimiento se repite  $n_a-1$  veces hasta conformar una cadena completa que representa un individuo factible. Dado que la población debe poseer  $n$  individuos este bucle se anida dentro de otro que se repite  $n$  veces (ver la Figura 6.44).

```

comienzo
na=número de actividades
n=tamaño de la población
para x=1 hasta na
    {
        cluster x= actividad x           //creación de una lista de clusters
    }
para x=1 hasta n
    {
        u=1
        para y=1 hasta na-1
            {
                selección aleatoria de dos clusters i y j de la lista
                cluster na+u = fusión(i,j)
                eliminar i y j de la lista de clusters disponibles
                añadir na+u a la lista de clusters disponibles
                u=u+1
            }
        }
    }
fin

```

Figura 6.44: Generación de una población de “n” árboles de corte (especies). Adaptado de [Santamarina, 95].

### 6.6.3 Evaluación de la adaptación de los individuos de la población al medio

Para la evaluación de la calidad de los diferentes individuos que componen la población se empleará como función de aptitud el Potencial del Árbol de Cortes definido en 6.4.1. Dicho

potencial es una función aditiva ponderada de dos tipos de potenciales, el relacional y el geométrico. El geométrico mide la capacidad del árbol para generar distribuciones geoméricamente válidas, y el relacional es una función de naturaleza multicriterio que estima la capacidad del árbol para generar distribuciones que cumplan los diferentes requisitos establecidos en el problema.

$$P_{ac} = Cg \cdot P_{gac} + Cr \cdot \frac{1}{1 + P_{rac}}$$

donde:

- $P_{ac}$  es el potencial del árbol de cortes;
- $P_{gac}$  es el potencial geométrico del árbol de cortes tal y como se define en Ec. 6.11;
- $P_{rac}$  es el potencial relacional del árbol de cortes tal y como se define en Ec. 6.10;
- $Cg$  y  $Cr$  son los coeficientes de ponderación representativos de la importancia relativa entre el criterio geométrico y relacional respectivamente;

La función evaluadora empleada es compleja y requiere de un número elevado de cálculos. De manera habitual, en un algoritmo genético la fase de evaluación es la que emplea proporcionalmente una mayor cantidad de tiempo y este caso no es una excepción. En el capítulo que posteriormente se dedicará a exponer los resultados experimentales de este trabajo, se mostrará que el porcentaje de tiempo empleado por la evaluación respecto de otras fases del algoritmo varía entre el 60 y el 90% del tiempo total de cada iteración, dependiendo de los parámetros elegidos para la ejecución. También se mostrará que dentro de la función evaluadora es el cálculo del potencial geométrico el que más tiempo y recursos emplea.

El potencial geométrico del árbol de cortes es por definición una función del ratio de la planta cuyo dominio de definición es el intervalo  $]0, \pi/4[$  o, alternativamente,  $]0, 90[$  si se emplean grados sexagesimales. Además, para cada una de las actividades hay que calcular los incumplimientos geométricos en función de los ratios de los subdominios a partir de los cuales son generados por partición. Todas estas funciones son, por construcción, continuas en su dominio de definición. La implementación informática del cálculo del potencial geométrico del árbol de cortes reviste cierta dificultad. Dado que no es operativo determinar la expresión analítica de estas funciones, se realiza una discretización de las mismas calculando sus valores en puntos uniformemente distribuidos a lo largo del dominio de definición. Estos valores almacenados son representativos de las diferentes funciones.

Evidentemente la mayor o menor fineza del muestreo es un parámetro importante que afecta a la precisión de los cálculos del potencial geométrico. En la Figura 6.45 (a) se presenta el potencial geométrico de un árbol de cortes en forma de función. En la figura (b) se ofrece un detalle ampliado de una zona concreta de dicha función. En la figura (c) se ofrece la misma función discretizada, tal y como es calculada por el algoritmo. Los rombos amarillos sobre la línea denotan puntos de muestreo, tomados en este caso en intervalos de 1 grado sexagesimal.

Se denomina **Pg** (precisión geométrica) al parámetro del algoritmo que controla la precisión del muestreo. Su valor indica el número de muestras tomadas por cada grado sexagesimal del intervalo de definición. Por defecto el valor de este parámetro es 1, y en los



experimentos realizados ha resultado adecuado. Un valor superior aumenta la precisión a costa de incrementar el tiempo de cálculo y los requerimientos de memoria para almacenar una mayor cantidad de datos.

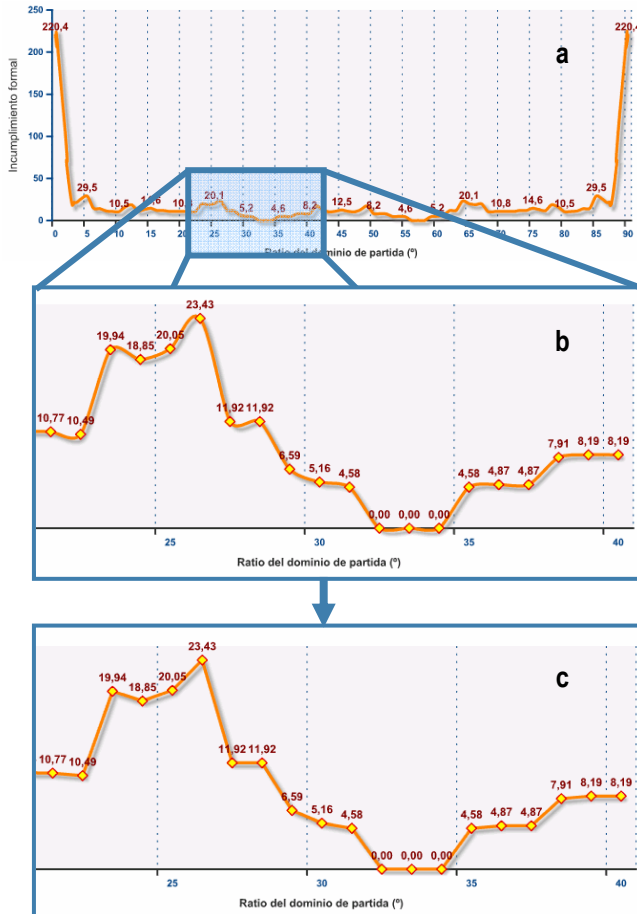


Figura 6.45: Discretización de funciones en el cálculo del potencial geométrico de los árboles de corte.

En la Figura 6.46 se representan de manera simultánea el valor real de la función y el obtenido mediante discretización. Los valores intermedios entre puntos muestreados se obtienen por interpolación lineal. El error cometido no es significativo y en los experimentos realizados el procedimiento empleado ha demostrado su eficacia.

En determinadas situaciones, como la mostrada en la Figura 6.47, sería conveniente aumentar la precisión geométrica. Sin embargo, el hecho de que por construcción las funciones tratadas sean continuas y derivables en su dominio de definición, y de que los incumplimientos geométricos varíen suavemente con las modificaciones de los ratios de los dominios, hace que no se produzcan situaciones como la de la Figura 6.47 y que, en general, una precisión geométrica de 1 provoque un error que no influye prácticamente en los

resultados del algoritmo.

Esto es algo común a los algoritmos genéticos que, como se vio en capítulos precedentes, obtienen buenos resultados con funciones de aptitud que son simplificaciones de las de evaluación. Es decir, son suficientemente insensibles al error, como para permitir utilizar expresiones simplificadas mediante, por ejemplo, la linealización.



Figura 6.46: Representación del error cometido al discretizar el potencial geométrico del árbol de cortes.



Figura 6.47: Error en la interpolación entre muestras del potencial geométrico del árbol de cortes.

## 6.6.4 Operadores genéticos en LAYAGEN

La función de aptitud establecida para el algoritmo LAYAGEN G es fuertemente multimodal; existen una gran cantidad de óptimos locales en espacio de soluciones. A esto hay que añadir la falta de localidad de la codificación escogida, que provoca que pequeños cambios en un cromosoma pueda generar grandes cambios en el individuo que representa y viceversa. Por otra parte la incoherencia de la codificación (existen cadenas que no representan individuos válidos) obliga a establecer mecanismos de tratamiento de los individuos infactibles.

Considerando estas premisas, antes de definir los operadores a emplear en LAYAGEN G se realiza un estudio pormenorizado del funcionamiento de los operadores genéticos empleados en LAYAGEN, analizando sus efectos sobre la población. Estos operadores han demostrado su efectividad y validez en el trabajo de Santamarina, sin embargo, el análisis realizado a continuación se lleva a cabo desde un punto de vista crítico, guiado por el afán de mejorar en lo posible su rendimiento. Posteriormente se establece el modo de actuar de los operadores genéticos en LAYAGEN G tratando de solventar los problemas identificados en los operadores de LAYAGEN.

### 6.6.4.1 Efectos de la selección y el reemplazo en LAYAGEN

En LAYAGEN la selección de los individuos que se reproducirán o los que sobrevivirán pasando a la siguiente generación se realiza por un mecanismo de ruleta (roulette wheel selection) [Goldberg, 89b], y el reemplazo es directo, los descendientes sustituyen a los progenitores.

La pérdida de orientación del algoritmo LAYAGEN sucede con cierta frecuencia. Considerando que el fenómeno no es debido a una selección incorrecta y demasiado elevada de las probabilidades de cruce y mutación, la causa más probable es la *epistasis*. Como ya se expuso en capítulos precedentes la *epistasis* es un fenómeno que ocurre cuando existe una fuerte interrelación entre dos o más genes, provocando que la contribución de un gen a la aptitud global del individuo dependa del valor que adopten otros genes. Esto dificulta la identificación de bloques constructivos apropiados.

En el sistema de codificación empleado un gen determinado puede expresar diversos aspectos fenotípicos según las circunstancias. Esto es, un gen que en un individuo actúa como hoja del árbol en otro individuo actúa como nodo, siendo esto función del alelo que lo ocupe. Por otra parte, un determinado esquema ocupando determinados genes de la cadena puede ser de elevada aptitud si en otra parte de la cadena se dan ciertas circunstancias, y de baja aptitud en caso de darse otras. Por ejemplo, en la Figura 6.48 puede suponerse que la secuencia que ocupa los seis primeros genes del primer cromosoma representado determina la aparición de un sub-árbol de cortes de elevada aptitud (el que pende del nodo 12) siempre y cuando su profundidad en el árbol (distancia al nodo raíz) no sea excesiva. La profundidad del nodo 12 dependerá del resto de la cadena, fundamentalmente (aunque no exclusivamente) de la posición que ocupe el alelo 12. Así pues, la misma secuencia de alelos ocupando los mismos genes en el segundo cromosoma de la figura, situarán el sub-árbol a gran profundidad, provocando una deficiente valoración de la misma secuencia que antes fue bien valorada.

Este fenómeno puede provocar que el algoritmo se desoriente en su búsqueda y que individuos especialmente prometedores, portadores de esquemas de alta calidad, sean desechados (no seleccionados) cuando al actuar sobre ellos un operador genético sean valorados circunstancialmente como de baja aptitud.

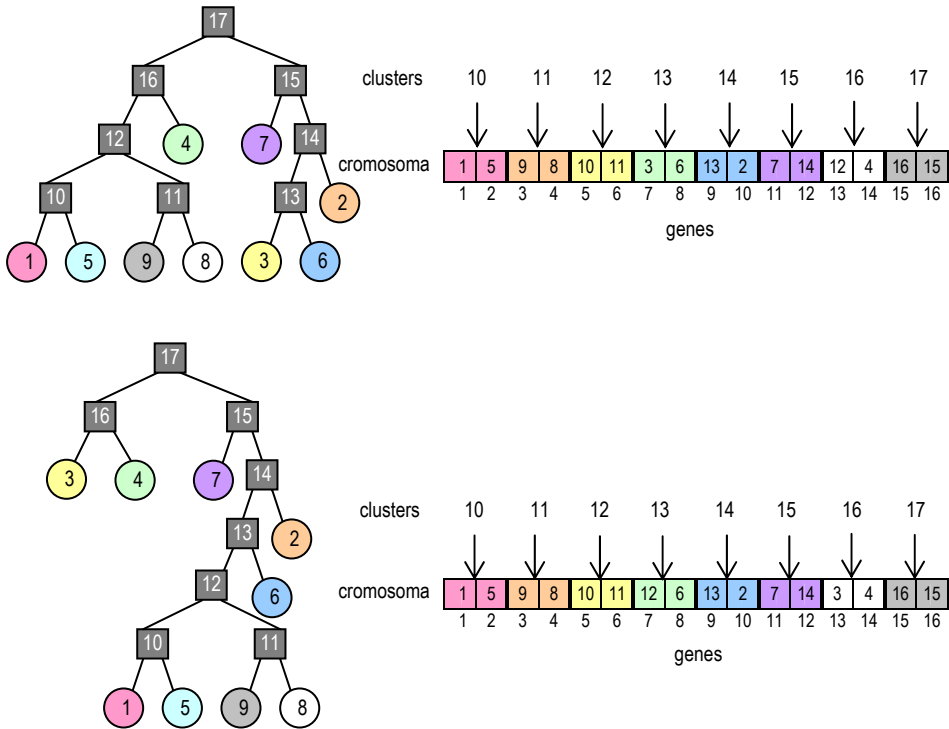


Figura 6.48: Ejemplo de epistasia.

### 6.6.4.2 Efectos del cruce en LAYAGEN

Como ya se expuso en el capítulo anterior, el operador cruce en LAYAGEN es monopunto, intercambiándose las subcadenas que quedan a cada lado del punto de cruce escogido. La Figura 6.49 muestra el mecanismo de cruce. El operador no es cerrado, existiendo probabilidad de dar como resultado individuos no factibles.

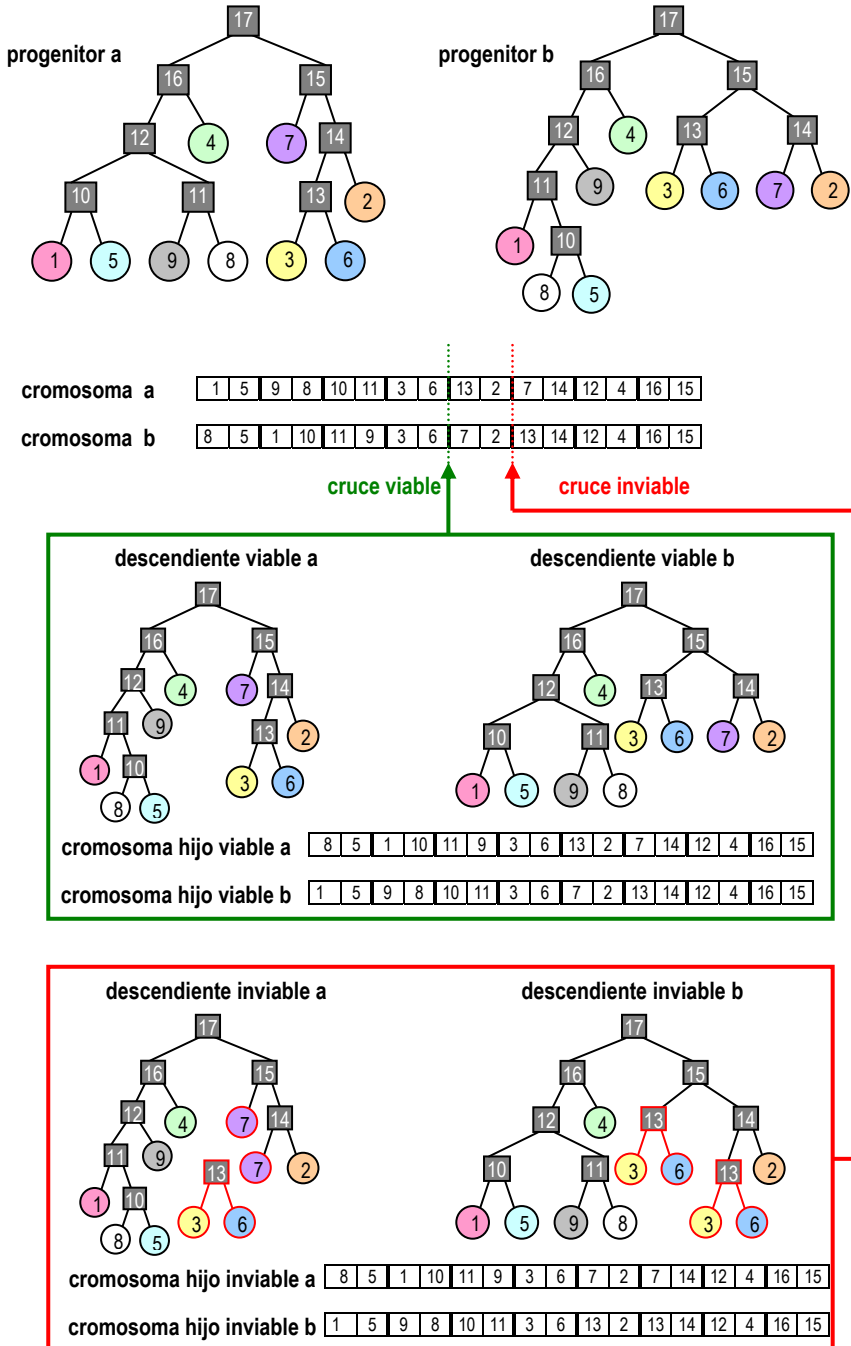


Figura 6.49: Cruce de dos especies en LAYAGEN para obtener híbridos interespecíficos. Casos de descendencia viable e inviable.

El análisis experimental de su funcionamiento permite detectar que este operador actúa de forma muy diferente en función del grado de convergencia de la población. Cuando los individuos de la población son muy disímiles entre sí, la probabilidad de que el cruce de dos individuos dé como resultado un individuo factible es muy baja, dado que para que esto ocurra es necesario que los genes a un lado y otro del punto de cruce posean los mismos alelos aunque sea en disposición diferente. Dado que la divergencia de la población es elevada esto ocurre en pocas ocasiones, y cuando ocurre suele implicar a genes de los extremos de la cadena, lo que implica que los escasos individuos factibles generados difieran poco de sus progenitores.

Cuando la población converge hacia un óptimo la probabilidad de que el operador cruce proporcione individuos factibles aumenta, sin embargo, dado que los individuos son muy similares, de nuevo la descendencia diferirá poco de los individuos implicados en el cruce. En la Figura 6.50, se representa esta situación. Los progenitores, procedentes de una población con alto grado de convergencia son muy similares, lo que provoca que las posibilidades de cruce viable sean muchas (las flechas rojas marcan los únicos puntos de cruce inviables). Sin embargo, de los 5 puntos de cruce que producen individuos factibles, 4 (flechas amarillas) producen descendencia exactamente igual a los progenitores, lo que transforma al cruzamiento en ineficaz.

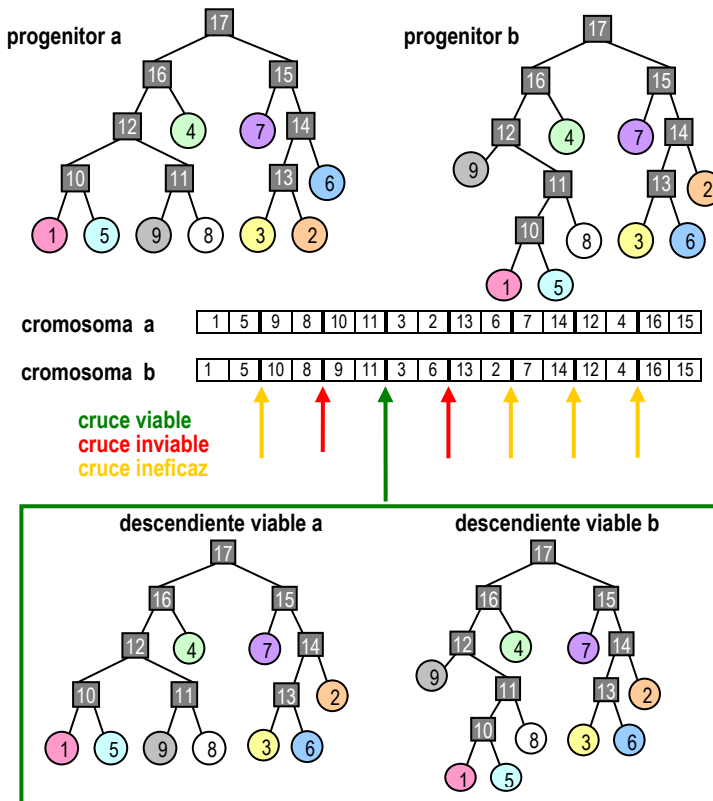


Figura 6.50: Efecto del operador cruce cuando existe similitud entre los progenitores.

### 6.6.4.3 Efectos de la mutación en LAYAGEN

Como se expuso en el capítulo anterior, la mutación en LAYAGEN es del tipo *intercambio de posición*; actúa intercambiando los alelos de dos genes escogidos aleatoriamente. Aunque habitualmente este tipo de operadores es cerrado no lo es en el caso de LAYAGEN, dado que puede ocurrir que el intercambio de alelos provoque la aparición en la cadena de un cluster todavía no formado.

Durante las experiencias realizadas empleando este tipo de mutación se pudo comprobar que los cambios producidos por el operador genético que daban como resultado individuos viables, afectaban en la mayor parte de los casos a las hojas del árbol, provocando el intercambio de la posición de dos actividades. En menor medida se producían intercambio de la posición de una actividad y un nodo, y en contadas ocasiones se intercambiaban las posiciones de dos nodos. Así, el intercambio válido más frecuente es el de las actividades que ocupan los genes primero y segundo, dado que estos necesariamente contienen actividades en cualquier cromosoma viable.

La posibilidad de que una mutación que afecte a genes que contienen nodos sea viable, es mucho más baja que la de aquellas mutaciones que afectan a genes que contienen actividades. Es posible intercambiar el contenido de dos genes cualquiera si estos poseen alelos que representan actividades. Sin embargo, si un gen contiene un cluster (equivalentemente un nodo del árbol) sólo puede ser intercambiado con genes situados más atrás en la cadena que el propio cluster. Por ejemplo, en la Figura 6.51 se representa un cromosoma en el que se indican en negrita aquellos genes que contienen clusters. Los únicos intercambios viables que afecten a dos clusters son la permutación de los genes 5-6,

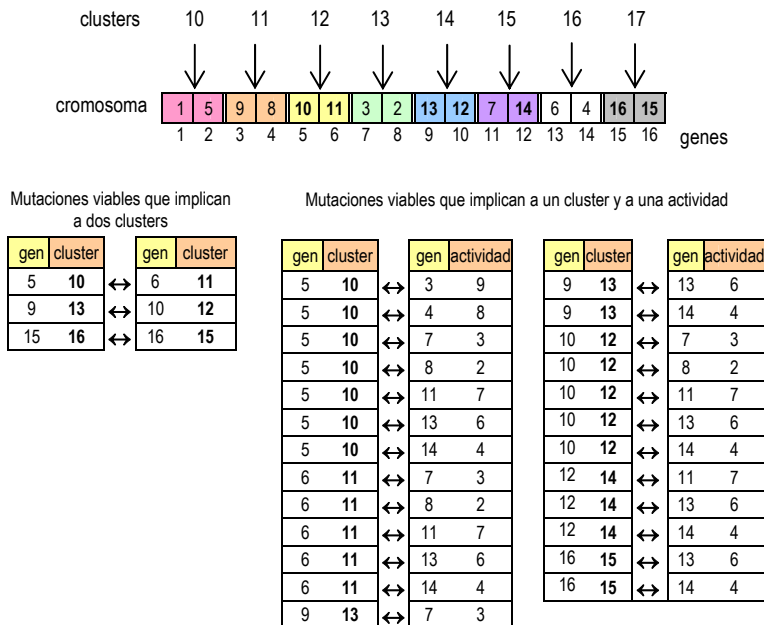


Figura 6.51: Mutaciones en un cromosoma que afectan a genes cuyo alelo representa un nodo del árbol de cortes.

9-10 y 15-16. El número de mutaciones viables que implican el intercambio de genes que contienen una actividad y un cluster o nodo es más elevado, aunque muchos de ellos no suponen un cambio importante en la estructura del árbol. Frente a esto existen 72 posibles mutaciones que afecten a dos actividades que en todos los casos resultarán viables.

Por supuesto, estas proporciones dependerán del cromosoma en cuestión, pero en general, las mutaciones significativamente más frecuentes son las que implican a dos actividades, lo cual supone un cambio somero en el árbol de cortes cuya estructura no se ve afectada. Además, existen cromosomas en los que estas proporciones son marcadamente más desfavorables a que las mutaciones afecten de manera decisiva a la estructura del árbol, es decir, existen individuos con una mayor resistencia frente a las mutaciones. Esto supone que existen ciertas zonas del espacio de soluciones de las que es más difícil para el algoritmo escapar mediante la búsqueda diversificadora que supone la mutación.

### 6.6.5 Operadores genéticos en LAYAGEN G

En el apartado anterior se ha llevado a cabo un análisis crítico del funcionamiento de los operadores genéticos que actúan en LAYAGEN. Ya se ha indicado que estos operadores han demostrado su eficacia en [Santamarina, 95], obteniendo buenos resultados en la búsqueda de árboles de cortes óptimos desde el punto de vista relacional. Sin embargo, los operadores que se definen a continuación tratan de, por una parte solventar los problemas detectados en los operadores de LAYAGEN, y por otra, adaptarlos a las condiciones de LAYAGEN G.

En el nuevo algoritmo se mantendrán los operadores clásicos: selección y reemplazo, cruce y mutación, introduciendo particularidades que aumentan su eficiencia en el contexto de la codificación empleada y la función de aptitud definida.

#### 6.6.5.1 Selección, reemplazo y elitismo

Una vez que una generación ha sido evaluada, la selección de los individuos que se reproducirán o los que sobrevivirán pasando a la siguiente generación se realiza por muestreo estocástico conservador, asignando a cada individuo una probabilidad de selección en función de su aptitud para sobrevivir en el medio, incluidos aquellos individuos menos aptos. De esta forma los individuos más adaptados tienen más probabilidad de sobrevivir, pero se proporciona alguna esperanza de supervivencia y reproducción a los menos dotados. En este punto se trata además el reemplazo; la forma en la que los individuos de la nueva generación sustituyen a los de la antigua.

##### 6.6.5.1.1 Selección

Se emplea un *mecanismo de ruleta* que, como se vio en capítulos precedentes, se desarrolla asignando a cada individuo una probabilidad que podría ser representada por un sector de una ruleta (de ahí el nombre del método de muestreo). A mayor adaptación del individuo, mayor es el sector que le corresponde en la ruleta y, por tanto, mayor probabilidad de resultar escogido. Evidentemente la suma total de las probabilidades de todos los individuos de la población es 1.



El funcionamiento detallado es el siguiente:

Dado que todos los individuos de la generación han sido evaluados se dispone de un valor que indica la aptitud de cada individuo. Sea  $x_i$  un individuo perteneciente a una población de  $m$  individuos. Sea  $\mu(x_i)$  la aptitud de  $x_i$  obtenida mediante el *Potencial* del árbol de cortes que representa. Dada la definición del Potencial del Árbol de Cortes, un mayor valor de  $\mu(x_i)$  indica una menor adaptación al entorno del individuo  $x_i$ , así pues se procede estableciendo las probabilidades de selección inversamente proporcionales al valor de  $\mu(x_i)$ .

Se calcula inicialmente el valor del potencial más elevado  $\mu_{\max}$  (el del individuo peor adaptado) mediante:

$$\mu_{\max} = \max \{ \mu(x_i) \}_{i=1 \dots m}$$

Conocido el valor  $\mu_{\max}$  se aplica la transformación:

$$\mu(x_i) = \mu_{\max} - \mu(x_i)$$

de tal manera que ahora los valores de  $\mu(x_i)$  son mayores para los individuos más adaptados y menores para los menos aptos, tomando la aptitud del individuo peor el valor 0. Se asignan ahora las probabilidades de selección de cada individuo como:

$$P(x_i) = \frac{\mu(x_i)}{\sum_{j=1}^m \mu(x_j)}$$

Conocidas las probabilidades de cada individuo, estos se ordenan de mayor a menor probabilidad. Una vez ordenados se calculan las probabilidades *acumuladas* de cada uno como la suma de la probabilidad propia y la de todos los que le preceden en esa ordenación.

$$P_{\text{acum}}(x_i) = \sum_{j=1}^i P(x_j)$$

De esta manera se obtienen una serie de intervalos consecutivos, comprendidos entre 0 y 1, cuyo tamaño es proporcional a la aptitud de cada individuo (análogamente se le asignaría un determinado sector de la ruleta). Para la selección se genera un número aleatorio entre 0 y 1 y se recorre la lista ordenada de individuos. El escogido será el primer individuo cuya




Figura 6.52: Analogía de la Selección por Ruleta.

probabilidad acumulada sea superior al número aleatorio.

#### 6.6.5.1.2 Reemplazo

El operador selección actúa tanto para escoger a los individuos reproductores como para seleccionar a los supervivientes, y lo hará tantas veces como el número de individuos a seleccionar. El reemplazo de los individuos de una generación por los de la siguiente se realiza de manera directa. Los individuos resultantes del cruce de los reproductores son siempre incluidos en la siguiente generación (reemplazo al vuelo o inmediato). De esta forma se determinan  $n \cdot Pc$  individuos de la población futura (siendo  $Pc$  la probabilidad de cruce).

El operador selección actúa de nuevo  $n \cdot (1 - Pc) - le_1$  veces para seleccionar otros tantos individuos que sobrevivirán a la actual generación pasando a la siguiente. Esta selección se realiza sobre todos los individuos de la población actual, incluyendo a aquellos que ya fueron seleccionados para reproducirse. Los individuos escogidos forman parte, de manera directa, de la nueva generación.

Por último,  $le_1$  individuos que destacan por su gran aptitud (la élite), son incluidos de forma directa en la nueva generación. De esta forma se ha producido una nueva generación de  $n$  individuos ( $[n \cdot Pc] + [n \cdot (1 - Pc) - le_1] + [le_1] = n$ ).

#### 6.6.5.1.3 La élite

En 6.6.4.1 se expuso la tendencia de LAYAGEN a la pérdida de orientación como consecuencia de *epistasis* o interrelación entre la expresión fenotípica de varios genes; un determinado esquema ocupando determinados genes de la cadena puede ser de elevada aptitud si en otra parte de la cadena se dan ciertas circunstancias, y de baja aptitud en caso de darse otras. Esto puede provocar que individuos portadores de esquemas de alta calidad sean desechados en un momento en que, circunstancialmente, obtienen una valoración baja de su aptitud.

Se denomina élite de la población al individuo o grupo de individuos más destacable por su aptitud. Dado que el procedimiento de selección empleado por los algoritmos genéticos implica cierto grado de aleatoriedad, no es posible garantizar que la élite sobreviva a la siguiente generación, y ni siquiera que sea seleccionada como reproductora. Esta circunstancia se agrava si existen fenómenos de epistasis. El empleo de estrategias elitistas implica la selección del mejor o de los mejores individuos de la población, y su introducción de manera directa en la siguiente generación.

La estrategia desarrollada en el presente trabajo actúa creando un *buffer* de individuos élite. El tamaño de dicho *buffer* es un parámetro del algoritmo que se denominará *intensidad de elitimo* ( $le_1$ ). Al comienzo de la evolución el *buffer* está vacío. Tras evaluar la primera generación el más apto de los individuos se introduce en la primera posición del *buffer* y pasa directamente a la siguiente generación. La evolución transcurre de esta manera, volcando el contenido del *buffer* en la población cada generación, hasta que se localiza un individuo cuya aptitud supera a la de cualquier individuo localizado hasta el momento. Dicho individuo se coloca en la primera posición del *buffer* pasando el individuo que estaba en dicha posición a la inmediatamente inferior. Este proceso se repite cada vez que se localiza un nuevo óptimo. El nuevo individuo entra al *buffer* ocupando la primera posición y

desplazando al resto hacia la parte inferior del *buffer*. Cada nueva generación el contenido es volcado en la población. Cuando el número de individuos alcanza el valor  $le_1$  el *buffer* se satura y es incapaz de albergar más cadenas. A partir de ese momento la adición de un nuevo individuo óptimo al *buffer* supone que el individuo que ocupa la última posición salga del mismo. El *buffer* es pues un pila tipo FIFO (*First In, First Out*).

El empleo de este mecanismo permite que cada nuevo óptimo localizado permanezca en la población el tiempo suficiente como para que pueda transmitir su carga genética asegurando que no desaparecerá por fenómenos epistáticos. Así, se permite una exploración más profusa del entorno de la élite, lo cual puede compararse a una intensificación de la búsqueda en esa zona.

Por otra parte, esta estructura en pila de la élite permite la presencia en la población de individuos de diversas épocas, por lo que la intensificación de la búsqueda no se centra en un único individuo, sino que se realiza una intensificación simultánea en diversas zonas prometedoras del espacio. Esto confiere al algoritmo cierto carácter estacionario [Whitley et al., 88; Syswerda, 89]. Conforme transcurre la evolución los individuos van saliendo de la élite y la búsqueda en su zona del espacio se detiene, a menos que en ella se haya localizado un nuevo óptimo que haya entrado en el *buffer*.

El tiempo de permanencia de los individuos élite en la población puede controlarse a través del parámetro  $le_1$ . Cuanto mayor es el tamaño de la pila élite más tiempo sobreviven sus individuos. El tamaño de la élite es un parámetro fundamental en la obtención de buenos resultados con esta estrategia, su empleo en poblaciones pequeñas puede resultar en convergencia prematura debido a la rápida disminución de la diversidad. Es recomendable que el tamaño de la población sea adecuado y además, que las probabilidades de cruzamiento y mutación sean suficientemente grandes para evitar la convergencia prematura.

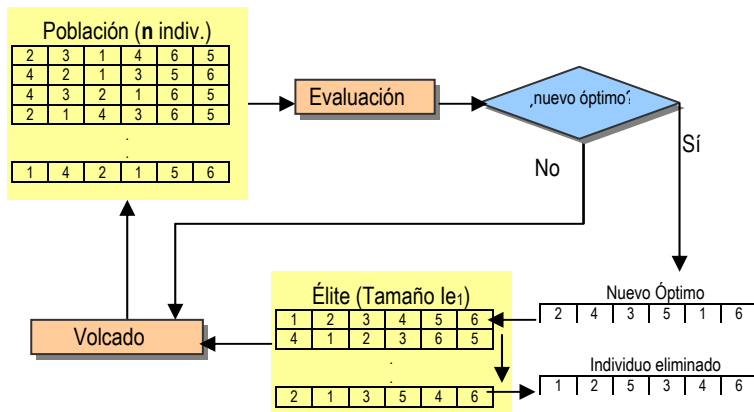


Figura 6.53: Estrategia elitista en LG1.

El empleo de una estrategia elitista no es recomendable cuando, como es el caso de este trabajo, la función de aptitud es multimodal. El empleo del elitismo en estas circunstancias puede aumentar el riesgo de convergencia prematura. De hecho Santamarina desestimó su empleo en LAYAGEN por hacer disminuir de esta manera su rendimiento. Sin

embargo, el empleo del elitismo en LG1 ha proporcionado buenos resultados evitando las pérdidas de orientación. Las medidas adoptadas sobre los operadores de mutación y cruce que serán expuestas posteriormente, aumentado sus capacidades diversificadoras, junto con el mantenimiento de una élite múltiple y diversa, parece ser suficiente para paliar los efectos indeseables de las estrategias elitistas sobre algoritmos con funciones de evaluación fuertemente multimodales. A esto hay que añadir que en el esquema general del algoritmo el operador mutación actúa sobre la población una vez que sobre ésta se han volcado los individuos élite. Esto implica que la élite puede verse sometida a cambios en su estructura que ayudan a evitar la convergencia prematura. Los individuos almacenados en el *buffer* se mantienen sin cambios.

### 6.6.5.2 Cruce

Durante el análisis del cruce en LAYAGEN se detectó que para poblaciones con alto grado de convergencia una elevada proporción de los cruces viables resultaban ineficaces, proporcionando descendencia idéntica a los progenitores. Esto disminuye la capacidad operativa del cruce. Como se explico en 6.6.4.2 esto ocurre también, por motivos diferentes, en etapas de divergentes de la evolución.

El operador que se emplea en LG1 es un cruce monopunto con ciertas particularidades en la selección del punto de cruce. El procedimiento es el que sigue:

Mediante el operador selección se escoge un par de individuos de la población que actuarán como progenitores. Se analizan todos los posibles puntos de cruce entre los dos individuos. Se desechan los puntos de cruce que producen descendencia inviable o idéntica a los progenitores. Se escoge el punto de cruce de manera aleatoria de entre los que no han sido desechados y se cruzan los individuos.

Para comprobar si un punto de cruce determinado genera descendencia viable, basta con recorrer los individuos progenitores hasta el punto de cruce, comprobando que los alelos presentes en un progenitor hasta dicho punto están presentes en el otro progenitor antes del punto de cruce. Si es así, la descendencia será viable puesto que no habrá alelos duplicados o faltantes. Como los individuos progenitores son viables por la propia definición del operador y por serlo todos los individuos de la población inicial, no es necesario comprobar que los alelos que representan los clusters no aparezcan en la cadena hasta que el cluster esté formado.

Si se cumple la condición de viabilidad se comprueba la de diversidad. Para ello basta comprobar que las subcadenas a cada lado del punto de cruce de los dos individuos son diferentes. Por ejemplo, si los genes que quedan a la izquierda del punto de cruce de uno de los progenitores poseen los mismos alelos y en el mismo orden que el otro progenitor, la descendencia será una copia de los padres. Lo mismo se debe comprobar para la subcadena derecha.

Puede ocurrir que ningún punto de cruce proporcione individuos viables diferentes. En ese caso se introducen en la lista de puntos de cruce posibles los que producen descendencia idéntica a los progenitores. Por último, puede suceder que ningún punto de cruce proporcione individuos viables, circunstancia en la cual se desechan los individuos seleccionados y se escogen otros dos progenitores.

Puede decirse que esta forma de proceder transforma al cruce en un operador cerrado, es decir, que genera solamente individuos factibles. Cuando posteriormente se exponga el funcionamiento del operador mutación se comprobará que posee la misma característica. Dado que los operadores son cerrados y la población inicial está formada por individuos factibles, se garantiza que todos los individuos que formarán parte de la población en las sucesivas generaciones representan árboles de corte con sentido. No obstante, el operador cruce aquí definido (y la mutación definida posteriormente) no son estrictamente cerrados, sino que emplean un mecanismo interno de tratamiento de las infactibilidades, en concreto el descarte.

En la Figura 6.54 se presenta el pseudocódigo del procedimiento para el caso genérico de un problema de  $n$  actividades en el que existen  $n-2$  posibles puntos de cruce:

```

comienzo
inda:=Selección(población); //selección de un progenitor de la población
indb:=Selección(población); //selección de un progenitor de la población
lista :=(); //creación de una lista de puntos de cruce válidos vacía
para x:=1 hasta n-2 //para cada punto de cruce posible...
{
  viable:=verdadero;
  diverso:= verdadero;
  //se comprueba si la subcadena izquierda de ambos padres posee los mismos alelos
  si [alelos_izq(inda)<> alelos_izq(indb)] entonces
    viable:=falso;
  si viable=verdadero entonces
    {
      //se comprueba si alguna subcadena de ambos padres posee los alelos en igual orden
      si {[orden_izq(inda)= orden_izq(indb)] ó [orden_der(inda)= orden_der(indb)]} entonces
        diverso:= falso;
    }
  si diverso = verdadero entonces
    lista :=lista + x; //se introduce el punto de cruce en la lista de puntos de cruce válidos
}
si lista = ∅ entonces //si la lista de puntos de cruce válidos está vacía...
  //se introducen los puntos de cruce que producen descendencia viable en la lista de puntos de cruce
  lista :=lista + x_viables;
si lista = ∅ entonces //si la lista de puntos de cruce viables está vacía...
  ir a comienzo //se comienza el proceso de nuevo
si no entonces //si la lista de puntos de cruce no está vacía...
  {
    punto_cruce:= aleatorio(lista); //se elige un punto de cruce aleatoriamente de entre los de la
  }
lista
  cruce (punto_cruce); //se cruzan los progenitores y se obtiene la descendencia
}

```

Figura 6.54: Determinación del punto de cruce en el operador cruce de LG1.

### 6.6.5.3 Mutación

La mutación empleada en LAYAGEN propicia el intercambio de genes cuyos alelos

representan actividades, en detrimento de aquellos cuyos alelos representan nodos. El primer tipo de intercambio no afecta de manera significativa a la estructura del árbol, dado que sólo se modifica la posición de las actividades en las hojas del árbol; el segundo tipo, al afectar a los nodos, produce modificaciones más profundas siendo mayor su efecto diversificador.

El operador diseñado para LG1 emplea dos mecanismos de mutación diferentes, ambos basados en el intercambio del contenido de dos genes. El primer procedimiento consiste elegir de manera aleatoria los dos genes cuyos contenidos se intercambiarán. Antes de proceder al intercambio se comprueba si el resultado del intercambio es viable, de no serlo se procede a la elección de dos nuevos pares de genes, garantizando de esta manera que el resultado del operador será un individuo factible. En todo individuo existen intercambios que producen individuos viables, lo que impide que la selección de genes se transforme en un bucle sin fin. No obstante, esto supone un incremento en el tiempo medio de aplicación del operador, incremento que apenas resultó significativo en el estudio de tiempos realizado en la fase experimental del presente trabajo.

Éste es el procedimiento de actuación del operador mutación que se empleará en condiciones normales de evolución. En la Figura 6.54 se presenta el pseudocódigo del procedimiento para el caso genérico de un problema de  $n$  actividades:

```

comienzo
ind:=Selección(población); //selección de un individuo de la población
viable:=falso;
mientras viable=falso hacer
{
  gen1:= aleatorio(2n-2); //se eligen dos genes aleatoriamente de entre los 2n-2 posibles de ind
  gen2:= aleatorio(2n-2);
  comprobar_viability(gen1, gen2); //se comprueba si el resultado del cruce es viable
  si viability=verdadero entonces //si es viable se establece la condición de salida del bucle
    viable:= verdadero;
}
mutación (gen1, gen2); //se intercambian los contenidos de los genes del individuo ind
fin
    
```

Figura 6.55: Actuación del operador mutación en LG1.

Ya se expuso que la falta de localidad de la codificación provoca que el efecto de la mutación afecte más o menos a la estructura de los árboles en función de los genes implicados. Existen cromosomas en los que estas proporciones son marcadamente más desfavorables a que las mutaciones produzcan cambios significativos, es decir, existen individuos con una mayor resistencia frente a las mutaciones, dado que el número de mutaciones viables que afectan a nodos es menor. Esto supone que existen ciertas zonas del espacio de soluciones de las que es más difícil para el algoritmo escapar mediante la búsqueda diversificadora que supone la mutación.

Por ejemplo, en los cromosomas de la Figura 6.56 existen diferencias en cuanto al número de intercambios viables que afecten a dos nodos; el primero de los cromosomas de la figura presenta una mayor resistencia a variar su estructura mediante mutación.

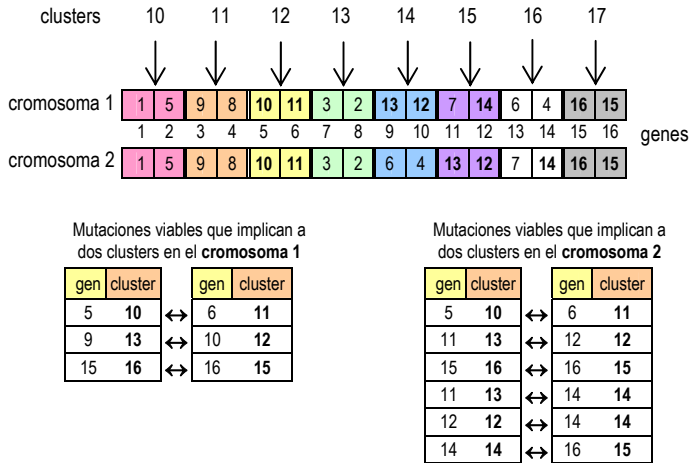


Figura 6.56: Cromosomas con diferente sensibilidad a la mutación.

Un segundo procedimiento de mutación se empleará cuando se produzca un nivel predeterminado de convergencia de la población. La intención es que este segundo mecanismo, con un poder diversificador mayor, logre que el algoritmo pueda escapar de óptimos locales<sup>50</sup>. Cuando la población converja hacia un óptimo local se empleará la falta de localidad de la codificación para provocar que las mutaciones que se produzcan, afecten preferentemente a genes que posean alelos que representen nodos. De esta manera la probabilidad de escapar hacia zonas inexploradas del espacio de soluciones aumenta.

Para exponer el segundo procedimiento de mutación es necesario establecer el mecanismo de intercambio de genes y determinar la manera de medir el grado de convergencia de la población. Se procederá exponiendo primero el mecanismo de mutación y, posteriormente, la medición de la convergencia.

### 6.6.5.3.1 Mutación geométrica

Se ha denominado *mutación geométrica* a este mecanismo de intercambio de genes, porque durante la etapa de experimentación pudo comprobarse que su empleo favorecía la localización de soluciones de muy elevada calidad geométrica. El motivo puede ser que su

<sup>50</sup> Existe una importante discusión en la bibliografía sobre la conveniencia de disminuir o aumentar la probabilidad de mutación durante la evolución. Ya se indicó en el capítulo dedicado a los algoritmos genéticos, que autores como Ackley, Brammlette, Fogarty o Michalewicz, por ejemplo, defienden que ésta debe disminuir basándose en la evidencia de sus experimentos, aunque no ofrecen un motivo razonado para ello. Sin embargo, en el caso de funciones de aptitud fuertemente multimodales, la probabilidad de que el algoritmo quede atrapado en un óptimo local es elevada, problema que puede ser solventado mediante una efectiva actuación del operador mutación. En el presente trabajo se optará por este último procedimiento.

empleo disminuye la probabilidad de que la mutación se limite a intercambiar dos actividades que cuelgan del mismo nodo. Este tipo de intercambios, con alta probabilidad de ocurrencia, pueden suponer un cambio respecto al coste asociado al flujo de materiales, pero no varía en absoluto la geometría de las actividades.

El mecanismo de actuación es similar al anteriormente descrito con la singularidad de que, además de que el resultado del operador debe ser un individuo viable, se exige que uno de los genes implicados en el intercambio debe contener un alelo que represente un nodo del árbol de cortes. Un procedimiento similar, en la que se fuerza una mutación más intensa, es la *Cataclysmic Mutation* empleada por Eshelman en su algoritmo CHC [Eshelman, 91], aunque este último procedimiento es mucho más agresivo.

En la Figura 6.57 se presenta el pseudocódigo del procedimiento para el caso genérico de un problema de  $n$  actividades:

```

comienzo
ind:=Selección(población); //selección de un individuo de la población
viable:=falso;
mientras viable=falso hacer
{
  nodo:= falso;
  mientras nodo =falso hacer
  {
    gen1:= aleatorio(2n-2); //se eligen dos genes aleatoriamente de entre los 2n-2 posibles de ind
    gen2:= aleatorio(2n-2);
    //se comprueba si alguno de los genes representa un nodo
    si [(gen1 es nodo) ó (gen2 es nodo)] entonces
      nodo:=verdadero;
  }
  comprobar_viabilidad (gen1, gen2); //se comprueba si el resultado del cruce es viable
  si viabilidad=verdadero entonces //si es viable se establece la condición de salida del bucle
    viable:= verdadero;
}
mutación (gen1, gen2); //se intercambian los contenidos de los genes del individuo ind
fin

```

Figura 6.57: Actuación del operador mutación geométrica en LG1.

#### 6.6.5.3.2 Medición de la convergencia de la población

Para medir la convergencia de la población existen diversos métodos en la bibliografía. Dos de los más extendidos son el propuesto en por Srinivas y Patnaik en 1994 [Srinivas et al., 94a] para determinar en tiempo real las probabilidades de mutación y cruce más adecuadas, y uno de los presentado por Goldberg y sus colaboradores en 1995 [Goldberg et al., 95]. El primero de ellos mide la convergencia de la población calculando la diferencia de los valores de la función objetivo para el mejor individuo, y para la media de todos los individuos. Cuanto menor sea el valor mayor es la convergencia; un valor igual a cero indica que todos los individuos son iguales. El segundo procedimiento, denominado "*bit-wise average convergence measure*", consiste en considerar la proporción de genes que han sido dominados por un determinado alelo en la población. Se considera que un gen ha convergido



a un alelo concreto cuando cierto porcentaje de la población tiene el mismo alelo en ese gen. Cuando el porcentaje de genes que han sido dominados por un alelo supera cierto umbral, se considera que la población ha convergido.

El primero de los sistemas basa la medición de la convergencia en el valor de las aptitudes de los individuos, mientras que el segundo mide las similitudes de las cadenas. Podría decirse que el primero considera los fenotipos y el segundo los genotipos. En el caso de LG1 se empleó el "*bit-wise average convergence measure*", puesto que la falta de localidad de la codificación hace más fiable medir la convergencia directamente sobre los cromosomas y no sobre la aptitud de los individuos.

El procedimiento detallado de medición de la convergencia empleado en LG1 es el siguiente:

```

comienzo
para x:=1 hasta 2n-2 hacer
  {
   $\theta_x$ := alelo más frecuente en el gen x;
  n( $\theta_x$ ):= veces que aparece el alelo dominante en el gen x;
  f( $\theta_x$ ):=n( $\theta_x$ )/tamaño_población; //frecuencia del alelo dominante en el gen x
  }
convergencia:=  $\sum f(\theta_x) / 2n-2$  //media de las frecuencias de los alelos dominantes en cada gen
fin

```

Figura 6.58: Medición de la convergencia en LG1.

En la generación en la que se desea medir la convergencia se recorren todos los individuos comprobando el alelo que ocupa el primer gen de la cadena. Determinado cuál es el alelo que está presente en más posiciones, se calcula el porcentaje de los individuos que posee dicho alelo en esa posición. Este procedimiento se repite para todos los genes. Establecido el porcentaje de convergencia de cada gen, se calcula el porcentaje de convergencia de la población como la media de los porcentajes de convergencia de cada gen. Si este valor supera un umbral determinado (**Pmg**, que se expresará en probabilidad en lugar de porcentaje), se considerará que existe convergencia. En la Figura 6.58 se presenta el pseudocódigo del procedimiento para el caso genérico de un problema de  $n$  actividades:

Al establecer el valor de **Pmg** debe considerarse, además de otros factores, que los últimos genes de la cadena sólo pueden adoptar alelos concretos, y su porcentaje de convergencia es necesariamente elevado. Durante la etapa de experimentación se obtuvieron buenos resultados estableciendo un porcentaje de convergencia de 0,9 como umbral para la actuación de la mutación geométrica. Este valor presenta una gran robustez, siendo adecuado para problemas de muy diferentes características.

Cuando el grado de convergencia supera **Pmg**, las mutaciones, que hasta el momento seguían el primero de los mecanismos descritos, pasan a actuar emplean el intercambio geométrico. Las mediciones de la convergencia se siguen realizando y cuando se retorna a valores por debajo de **Pmg** deja de actuar la mutación geométrica.

Como indican Srinivas y Patnaik, debe actuarse con precaución para evitar que el aumento de la diversificación de la búsqueda cuando la población converge a un óptimo local

impida también que se converja al óptimo global. Para evitar esto, estos autores hacen variar las probabilidades de mutación y cruce no sólo en función del grado de convergencia de la población, sino también en función del individuo al que van a ser aplicados los operadores. Si la calidad del individuo es elevada se procura disminuir el efecto de los operadores. En LG1, el empleo de la estrategia elitista antes descrita impide que el aumento del poder diversificador de la mutación rompa las mejores estructuras localizadas en varias zonas del espacio de soluciones.

### 6.6.6 Intensificación de la búsqueda; hibridación del algoritmo

Los algoritmos genéticos demuestran una elevada capacidad para localizar soluciones globalmente competitivas, sin embargo, difícilmente son capaces de explotar los alrededores de los individuos localizados. Por su parte, los métodos de búsqueda local son capaces de, partiendo de una solución dada, *escalar* ("climb" en la literatura) por el espacio de soluciones cercano al punto de partida localizando el óptimo local. Las capacidades complementarias de ambas técnicas ha conducido a la aparición de métodos híbridos; algoritmos genéticos en los que se introducen, de muy diversas maneras, técnicas de búsqueda local.

Existe, sin embargo, cierta polémica en la literatura sobre el modo en que afecta la búsqueda local a la eficiencia de la búsqueda global del algoritmo. Algunos autores estiman que el cambio que provoca la búsqueda local en la información generada por el propio algoritmo puede producir la pérdida de los esquemas heredados por la descendencia. No obstante, este tipo de métodos proporcionan en la práctica una mejora de los resultados respecto a las técnicas puras.

Es habitual emplear técnicas de mejora local sobre cada uno de los individuos localizados mediante búsqueda genética después de cada generación [Davis, 91; Muhlenbein, 91]. Este procedimiento tan intensivo, puede afectar a los esquemas de alta calidad localizados por el algoritmo en mayor medida que otro tipo de métodos en los que la búsqueda local se lleva a cabo cada cierto número de generaciones, o bien, basándose en cierta probabilidad [Mathias et al., 94].

Dentro del flujo normal de LG1, se propone introducir etapas de búsqueda local procurando no intensificarlas excesivamente. Para ello se realizará una búsqueda de ámbito local en la vecindad sólo de algunos de los individuos de la población cada cierto número de generaciones.

Ya se ha expuesto que el espacio de soluciones del problema es abrupto, coexistiendo en la misma vecindad de una solución valores muy distintos de aptitud. Debido a la función de evaluación de las soluciones empleada y a la codificación de las mismas, es posible que un cambio mínimo en la cadena de una solución mediocre, transforme a ésta en una solución cuasi-óptima. Este tipo de desniveles bruscos en el campo de soluciones es denominado acantilados de Hamming [Schaffer et al., 89] (ver Figura 6.59).

En el transcurso de la evolución aparecen individuos de calidad aceptable que permanecen en la población durante varias generaciones. En ocasiones, un pequeño cambio en la codificación de estos individuos los transformaría en individuos de elevada calidad, sin embargo, terminan desapareciendo cuando la búsqueda encuentra mejores zonas del espacio de soluciones en las que centrarse, o bien, simplemente, no les es favorable la




Figura 6.59: Intensificación local de la búsqueda.

componente aleatoria del algoritmo. Se propone introducir, dentro de la evolución del algoritmo, periodos de búsqueda en el entorno inmediato de las soluciones que conforman la población, para tratar de localizar dicho tipo de individuos cercanos a una depresión del espacio de soluciones y explotarlos al máximo. Podría decirse que es una etapa de *ajuste fino* del algoritmo.

El procedimiento es análogo (salvando las distancias) a la etapa intensificadora de un algoritmo tabú. Para su implementación debe poderse pasar de una posición del espacio de soluciones a otra cercana mediante variaciones de la codificación de la solución actual (*movimiento*). Las posiciones del espacio accesibles mediante un movimiento formarán el *entorno* de la solución actual. Evidentemente, la definición de *movimiento* delimitará el entorno o vecindario de una solución. La función evaluadora de la calidad de un movimiento será la función de coste del algoritmo.

Se propone definir movimiento como el intercambio de los alelos de dos genes (definición similar a la de la mutación), por lo que el vecindario de una solución queda definido como todas las posibles soluciones a las que es posible acceder mediante el intercambio de dos genes de la solución actual. Empleando esta definición, el procedimiento será similar al utilizado por Goldberg en su *emulación del gradiente* [Goldberg, 89b].

Para decidir si el algoritmo entra en una etapa intensificadora pueden emplearse criterios relacionados con la convergencia de la población o, simplemente, aplicarlos cada cierto número de iteraciones. En este trabajo se opta por la segunda alternativa, definiendo el parámetro **Fib** (frecuencia de intensificación de la búsqueda) como el número de generaciones que debe transcurrir hasta que el algoritmo entra en una fase de intensificación. Cuando se cumple la condición, el algoritmo escoge cierto número de individuos de la población **lib** (Intensidad de la intensificación), recorriendo todo el vecindario de cada individuo. Si se localiza una solución mejor, el individuo en cuestión es substituido por el vecino que lo mejora. En la Figura 6.61 se presenta el pseudocódigo del procedimiento

para el caso genérico de un problema de  $n$  actividades.




Figura 6.60: Entorno de una solución.

Durante la etapa experimental se probaron tres mecanismos para la selección de los individuos que se someterían al proceso de búsqueda local. El primero de ellos fue la selección aleatoria de  $lib$  individuos de la población, el segundo fue seleccionar los  $lib$  individuos de la población con mejor valoración y el tercero aplicar el operador selección antes definido para escoger los individuos. En general, resulto más eficiente la utilización del operador selección, por lo que se optó por el tercer procedimiento. Además, se introduce la opción, que en general mejora los resultados del algoritmo, de someter a intensificación local a cualquier individuo que entre en la élite, es decir a cada nuevo óptimo localizado. A este último procedimiento se le denominará *intensificación de la élite*.

```

comienzo
para x:=1 hasta lib hacer
{
selección (ind); // se elige un individuo ind de la población mediante el operador selección
valor_inicial:= evaluar(ind); // se evalúa el individuo ind y se almacena su valor
mejor_valor:= valor_inicial;
cambiar:= falso;
para y:=1 hasta 2n-3 hacer
para z:=y+1 hasta 2n-2 hacer // se recorren los genes de ind
{
ind':= ind(y ↔ z); // el individuo ind' se genera intercambiando los genes y y z de ind
valor_vecino:= evaluar (ind'); // se evalúa el individuo ind' y se almacena su valor
// si el vecino es mejor que el original o cualquier vecino visitado se registradicho vecino
si valor_vecino < mejor_valor entonces
{
cambiar:= verdadero;
mejor_valor:= valor_vecino;
y':=y;
z':=z;
}
}
}
si cambiar = verdadero entonces //se sustituye ind por el mejor vecino que lo supere si
existe
ind(y' ↔ z');
}
fin
    
```

Figura 6.61: Procedimiento de intensificación local de la búsqueda.

El periodo de intensificación propuesto puede considerarse como un operador de mejora local (*local improvement operator*) como los propuestos por Shu y Van Gucht [Suh et al., 87] que incorpora información de tipo heurístico en la búsqueda genética. Un esquema del algoritmo híbrido resultante se ofrece en la Figura 6.62.

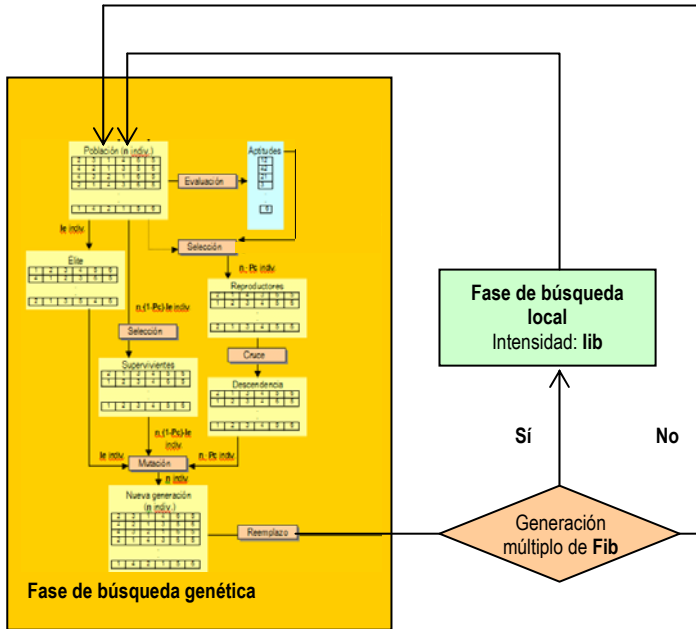


Figura 6.62: Esquema de las fases genética y de búsqueda local de LG1.

### 6.6.7 Finalización de LG1 y transición a LG2

Cuando se alcanza el número de generaciones ( $N_g$ ) establecido, la fase LG1 de LAYAGEN G finaliza, y el algoritmo comienza la segunda fase LG2. Como resultado de LG1 se tiene el árbol de cortes con mayor capacidad potencial para generar distribuciones que cumplan los diferentes criterios considerados que ha sido posible localizar. Cuando en el problema planteado el ratio de la planta es conocido y fijo, el árbol de cortes es el único resultado de LG1 que pasa a LG2. Si el dominio de la planta es variable en un intervalo determinado, LG1 concluirá proponiendo el mejor de los árboles de corte encontrado para su explotación en la segunda fase y, además, el ratio óptimo de la planta para dicho árbol.

El ratio óptimo o recomendado ( $\alpha_{recom}$ ) es aquél ratio perteneciente al intervalo de ratios permitidos para la planta ( $[\alpha_{min}, \alpha_{max}]$ ) para el que el potencial geométrico del árbol de cortes es mínimo (Figura 6.63). Se establece como opción para el planificador el escoger si la búsqueda en la segunda fase se realizará considerando que el ratio de la planta es fijo e igual a  $\alpha_{recom}$ , o si por el contrario, se continúa la búsqueda sobre todo el intervalo de ratios permitido para la planta.




Figura 6.63: Ratio recomendado para plantas con ratio variable.

## 6.7. La segunda fase de LAYAGEN G (LG2)

La segunda fase de LAYAGEN G (que se denominará en adelante LG2) posee una estructura similar a la segunda fase de LAYAGEN, implantándose cambios en la función evaluadora, introduciéndose una estrategia elitista y un proceso de intensificación de la búsqueda en los casos de plantas con ratios no fijados.

LG2 comienza generando una población inicial de  $n$  individuos. Cada una de las cadenas es evaluada mediante una función de aptitud que se definirá más adelante, obteniendo así una medida de su aptitud para sobrevivir y reproducirse.

En LG2, como en LG1, se define la probabilidad de cruce ( $P_c$ ), como la proporción de la siguiente generación que estará constituida por individuos que son el resultado del cruce de dos miembros de la generación anterior. Así pues, si  $P_c=0,8$  el 80% de la nueva generación será generado mediante cruce. Para ello se seleccionan  $0,5 \cdot n \cdot P_c$  parejas de individuos de la población. Cada pareja se cruza dando lugar a dos nuevos individuos que pasan directamente a la nueva generación.

También en LG2 se emplea una estrategia elitista. Una cierta cantidad de individuos ( $I_{e2}$ ) se conserva de generación en generación, el resto de la nueva generación,  $n(1-P_c)-I_{e2}$  individuos, se selecciona de la población, estando incluidos en el proceso selectivo los individuos que han participado en la reproducción. La selección tanto de los individuos reproductores como de los supervivientes se realiza mediante muestreo estocástico conservador. La élite se selecciona de manera directa, no siendo sometida a un proceso aleatorio de selección.

Sobre los individuos que conformarán la nueva generación actúa el operador mutación. De nuevo, en LG2 la probabilidad de mutación ( $P_m$ ) se define como la proporción de

individuos que se verá afectada por la mutación. Así pues, si  $P_m=0,5$ , el 50% de la población recién creada se someterá al operador mutación. Los individuos que mutarán se seleccionan de manera totalmente aleatoria de entre los obtenidos en los procesos anteriores: los supervivientes, los descendientes y la élite.

La nueva generación así creada será de nuevo evaluada y sometida a los operadores genéticos dando lugar a otra generación. Este procedimiento se repite hasta que se realice un número prefijado de iteraciones ( $N_g$ ).

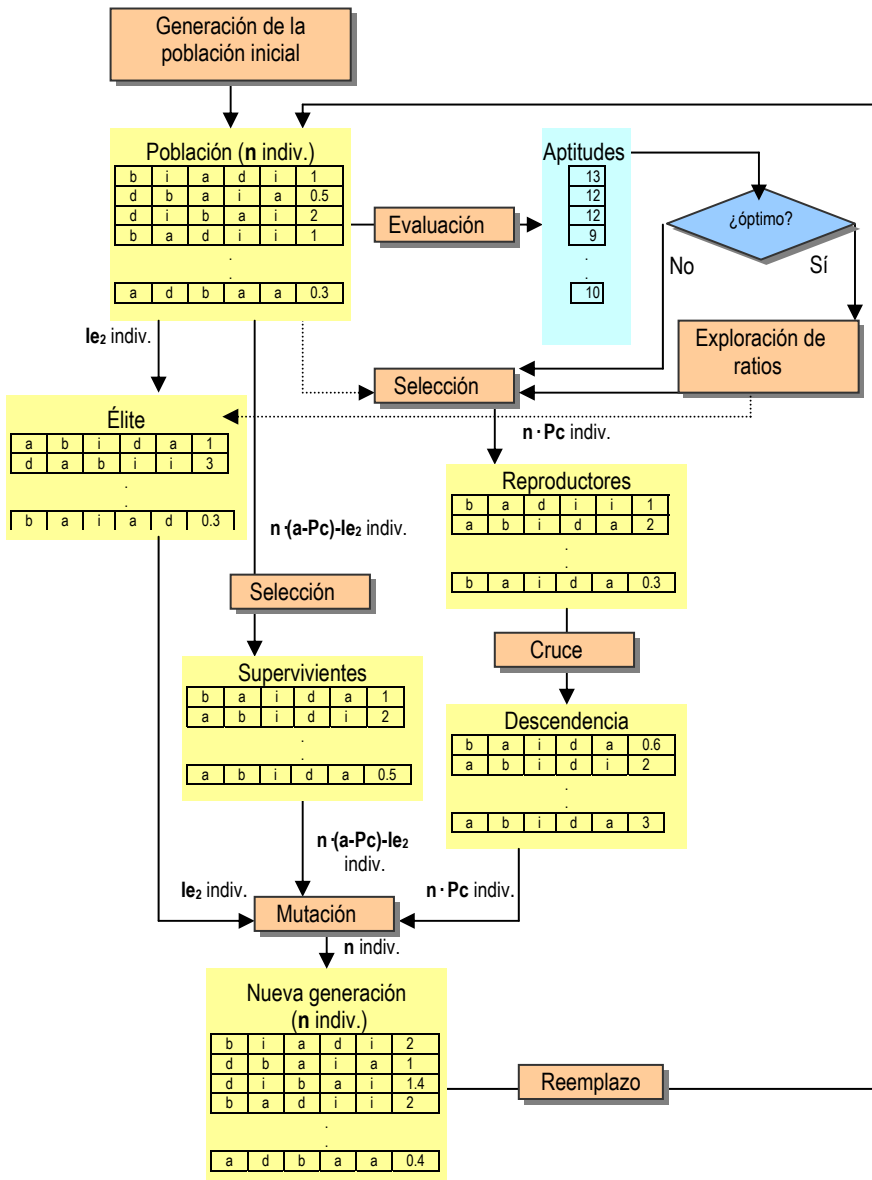


Figura 6.64: Esquema general de LG2.

Se detallan en los siguientes apartados: la forma de codificar las soluciones, la forma de generar la población inicial de distribuciones, la forma de evaluar las soluciones, los operadores genéticos y la estrategia elitista empleada, y el mecanismo de intensificación de la búsqueda implementado.

### 6.7.1 Codificación de las soluciones y generación de la población inicial

La codificación/descodificación de las distribuciones generadas por el árbol de cortes en cadenas de longitud finita se lleva a cabo con un mecanismo un tanto diferente al propuesto por Tam y posteriormente adoptado por Santamarina, y que ha sido expuesto en el capítulo anterior. Se emplean cadenas de genes cuyos alelos indican el tipo de corte a realizar en cada nodo del árbol, pero el modo ordenar los genes en la cadena sigue un procedimiento distinto.

Se establecen los cuatro tipos de corte habituales llamando “a” al corte horizontal que coloca la primera actividad implicada en el subdominio superior obtenido, “b” al corte horizontal que coloca la primera actividad implicada en el subdominio inferior de los obtenidos, “i” al corte vertical que establece la primera actividad implicada en el subdominio izquierdo obtenido, y “d” al corte vertical que coloca la primera actividad implicada en el subdominio superior obtenido.

Para codificar un individuo una vez establecidos los tipos de cortes, los procedimientos ya expuestos realizan un recorrido preorden del árbol introduciendo la información de los cortes de cada nodo visitado en la cadena. Por último, en el caso de LAYAGEN, se añade la información del ratio alto-ancho de la planta en el último gen del cromosoma, que puede tomar valores en el intervalo comprendido entre los ratios máximos y mínimos permitidos ( $[r_{\min}, r_{\max}]$ ).

El procedimiento empleado en LG2 varía en la forma de introducir los cortes en la cadena. En lugar de seguir la estructura del árbol de cortes mediante un recorrido preorden de sus ramas, la codificación sigue la estructura de la cadena que representa a dicho árbol. Es decir, en lugar de recorrer el árbol e ir añadiendo los genes al cromosoma de la distribución en el orden en el que se visitan los nodos, se recorre el cromosoma del árbol y se añaden los genes al cromosoma de la distribución en el orden en el que aparecen los clusters en él (ver Figura 6.65). Así pues, el primer gen del cromosoma de la distribución indicará el corte a realizar en el primer nodo creado del árbol, es decir, las dos primeras actividades agrupadas (en la figura el cluster 6). El segundo gen contendrá información del segundo nodo creado y así sucesivamente. El penúltimo gen de la cadena representará el tipo de corte realizado en el nodo raíz (cluster 9 en la figura), y el último el ratio alto-ancho de la planta. Así pues, una distribución de  $m$  actividades queda representada por una cadena de  $m$  genes.

La generación de la población inicial de individuos se realiza de manera aleatoria, es decir, se generan los cromosomas introduciendo de manera aleatoria los alelos en cada cadena. Dado el sistema de codificación empleado, la única precaución a adoptar para lograr individuos factibles es que el valor del último gen esté comprendido en el intervalo de ratios



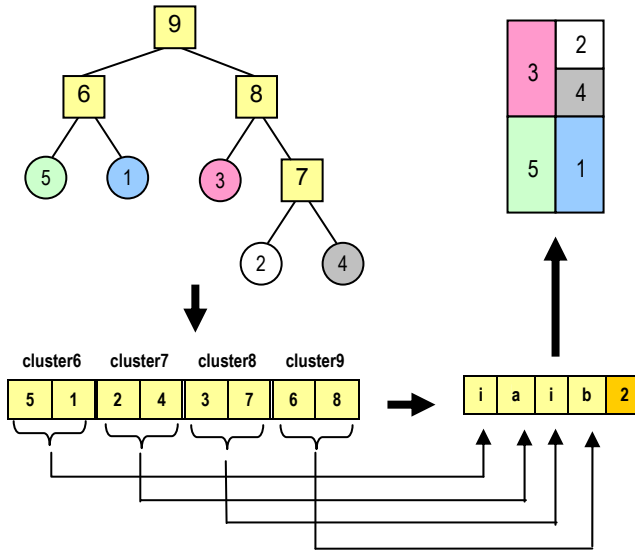


Figura 6.65: Codificación de las distribuciones de un árbol de cortes en LG2.

permitido de la planta. El tamaño de la población es de  $n$  individuos<sup>51</sup>.

### 6.7.2 La función de aptitud

Para evaluar la calidad de las soluciones representadas por cada cromosoma se empleará, para el caso de  $n$  actividades, una función de la forma:

$$F = C_r \sum_{i=1}^n \sum_{j=1}^n d_{ij} \cdot \left[ \pm \sum_{u=1}^k \alpha_u \cdot f_{u,ij} \right] + \frac{C_g}{g_c + 1} \cdot \sum_{i=1}^n (\mu_i \cdot l_i + 1)^p$$

con:

$C_r, C_g$ : coeficientes de ponderación de la importancia relativa entre los criterios relacionales y geométricos.

$d_{ij}$ : distancia<sup>52</sup> entre los centros de gravedad de las actividades  $i$  y  $j$ .

$k$ : número de criterios relacionales contemplados.

$\alpha_u$ : importancia relativa del criterio  $u$ -ésimo respecto al resto de criterios relacionales.

<sup>51</sup> El parámetro  $n$ , tamaño de la población, adopta el mismo valor para las dos fases del algoritmo. No sería inconveniente elegir valores diferentes para cada fase si se considerara necesario.

<sup>52</sup> La distancia podrá adoptar la forma deseada, siendo lo más habitual en la bibliografía la Manhattan y la Euclídea.

$f_{u,ij}$ : valor de la *intensidad relaciona*<sup>53</sup> de las actividades  $i$  y  $j$  bajo el criterio  $u$ -ésimo.

$l_i$ : penalización por el incumplimiento de las restricciones geométricas de la actividad  $i$ .

$\mu_i$ : rigidez de las restricciones geométricas impuestas a la actividad  $i$ . Toma valores entre 0 y 1.

$p$ : exponente de la penalización geométrica, parámetro que toma valores entre 1 e infinito que pretende aumentar de forma potencial la penalización cuando aumenta el incumplimiento geométrico.

$g_c$ : número de actividades en la distribución actual que cumplen con las restricciones geométricas del problema.

La función anterior guarda similitud con la empleada en LAYAGEN, sobre todo en el primer término del segundo miembro, en el que se evalúa en la disposición dada de las actividades el coste del transporte de materiales, o de cualquier otro coste empleado como criterio.

En el segundo término del segundo miembro se evalúa el grado en el que la distribución cumple las restricciones geométricas impuestas a las áreas asignadas a las actividades. Para ello se calcula el valor del incumplimiento de cada actividad  $l_i$  y se pondera por un coeficiente  $\mu_i$  propio de cada una.  $l_i$  se calcula tal y como se hace en LAYAGEN;  $\mu_i$  indica la rigidez de las restricciones geométricas de la actividad  $i$ . Existen actividades que necesitan ser asignadas a áreas con formas concretas para poder desarrollarse, mientras que otras ofrecen cierto grado de tolerancia;  $\mu_i$  tomará un valor cercano a 1 si las restricciones son estrictas, y disminuirá proporcionalmente al grado de tolerancia en la forma del área asignada a la actividad. Un sistema de ponderación similar se emplea en [Tam et al., 98].

En el cálculo de la penalización del incumplimiento geométrico se introduce en el denominador el número de actividades que cumplen con las restricciones geométricas  $g_c$ . El motivo se expone a continuación:

Supónganse dos casos particulares. Una distribución en la que la mayor parte de las actividades no cumplen las restricciones geométricas, pero cuyo incumplimiento es pequeño, es decir, "casi" cumplen (ver Figura 6.66 a), y una distribución en la que la mayor parte de las actividades cumplen los requisitos geométricos salvo alguna que tiene un elevado incumplimiento (Figura 6.66 b).

Si el incumplimiento en la actividad de la segunda distribución es elevado, la distribución a) será mejor valorada a pesar de que el número de actividades no válidas es mayor. Esto resulta un problema por algo que se constató durante el proceso de experimentación, y que, ya en 1995, afirmaban Tate y Smith [Tate et al., 95]. El grado de incumplimiento de las restricciones geométricas de actividades individuales, es menos importante en el proceso de búsqueda que el número de departamentos que incumplen las restricciones. Es decir, es más sencillo llegar a soluciones válidas desde una distribución como la segunda del ejemplo (con pocas actividades no válidas aunque muy alejadas de los requerimientos) que desde una distribución en la que la mayor parte de las actividades están próximas a cumplirlas pero no lo hacen.

<sup>53</sup> Se emplea la intensidad relacional como se define en [Hospitaller et al., 86] :

$$w_{ij} = f_{ij} + \alpha \cdot tra_{ij}$$


siendo:

$f_{ij}$  la carga de transporte entre las actividades  $i$  y  $j$

$tra_{ij}$  la necesidad de proximidad entre las actividades  $i$  y  $j$  estimada mediante la tabla relacional de actividades

$\alpha$  coeficiente que pondera la importancia relativa de ambos criterios

Así pues, se consideró necesario introducir el número de actividades de la distribución que cumplen los requisitos geométricos en la expresión de la función de aptitud. Se hace de manera tal, que se valorara positivamente la existencia de un mayor número de actividades geoméricamente válidas.



*Figura 6.66: Distribuciones con actividades con diferente grado de incumplimiento de las restricciones geométricas.*

### 6.7.3 Operadores genéticos en LG2

Los operadores cruce y mutación son los definidos en [Santamarina, 95] para la segunda fase de LAYAGEN. El operador cruce es monopunto; para individuos de  $n$  actividades el punto de cruce se selecciona aleatoriamente entre 1 y  $n$ . El operador mutación selecciona de manera aleatoria un gen de la cadena y cambia su alelo también aleatoriamente. En este caso el gen seleccionado puede ser el que indica el ratio de la planta. Si éste es el caso, el alelo seleccionado debe pertenecer al intervalo de ratios permitidos; si no es así, se escoge uno de los cuatro tipos de cortes. Los modos de actuación de estos operadores pueden consultarse en el capítulo precedente.

La selección es un procedimiento de ruleta en el que la probabilidad de selección es proporcional a la calidad del individuo, medida mediante la función de aptitud descrita en el apartado anterior. El operador selección actúa tanto para escoger a los individuos reproductores como para seleccionar a los supervivientes, y lo hará tantas veces como el número de individuos a seleccionar. El reemplazo de los individuos de una generación por los de la siguiente se realiza de manera directa. Los individuos resultantes del cruce de los reproductores son siempre incluidos en la siguiente generación (reemplazo al vuelo o inmediato). De esta forma se determinan  $n \cdot P_c$  individuos de la población futura (siendo  $P_c$  la probabilidad de cruce).

El operador selección actúa de nuevo  $n \cdot (1 - P_c) - I_e$  veces para seleccionar otros tantos individuos que sobrevivirán a la actual generación pasando a la siguiente. Esta selección se

realiza sobre todos los individuos de la población actual, incluyendo a aquellos que ya fueron seleccionados para reproducirse. Los individuos escogidos forman parte, de manera directa, de la nueva generación.

Por último,  $le_2$  individuos que destacan por su gran aptitud (le élite), son incluidos de forma directa en la nueva generación. De esta forma se ha producido una nueva generación de  $n$  individuos ( $[n \cdot Pc] + [n \cdot (1-Pc) - le_2] + [le_2] = n$ ).

### 6.7.3.1.1 La élite

De la misma forma que en LG1, se implementa en LG2 una estrategia elitista que actúa creando un *buffer* de individuos élite estructurado como una pila tipo FIFO (*First In, First Out*). El tamaño de la pila es un parámetro del algoritmo que se denominará *intensidad de elitimo* ( $le_2$ ). Al comienzo de la evolución el *buffer* está vacío. Tras evaluar la primera generación el más apto de los individuos se introduce en la primera posición del *buffer* y pasa directamente a la siguiente generación. La evolución transcurre de esta manera, volcando el contenido del *buffer* en la población cada generación, hasta que se localiza un individuo cuya aptitud supera a la de cualquier individuo localizado hasta el momento. Dicho individuo se coloca en la primera posición del *buffer* pasando el individuo que estaba en dicha posición a la inmediatamente inferior. Este proceso se repite cada vez que se localiza un nuevo óptimo. Cuando el número de individuos alcanza el valor  $le_2$  el *buffer* se satura y es incapaz de albergar más cadenas. A partir de ese momento la adición de un nuevo individuo óptimo al *buffer* supone que el individuo que ocupa la última posición salga del mismo.

Esta estructura en pila de la élite permite la presencia en la población de individuos de diversas épocas, por lo que la intensificación de la búsqueda no se centra en un único individuo, sino que se realiza una intensificación simultánea en diversas zonas prometedoras del espacio. Esto confiere al algoritmo cierto carácter estacionario [Whitley et al, 88; Syswerda, 89]. Conforme transcurre la evolución los individuos van saliendo de la élite y la búsqueda en su zona del espacio se detiene, a menos que en ella se haya localizado un nuevo óptimo que haya entrado en el *buffer*. El tiempo de permanencia de los individuos élite en la población puede controlarse a través del parámetro  $le_2$ .

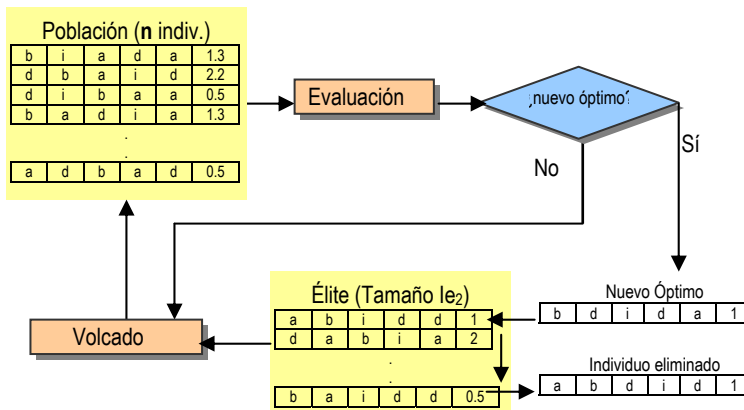


Figura 6.67: Estrategia elitista en LG2.

El empleo de elitismo en poblaciones pequeñas puede resultar en convergencia prematura debido a la rápida disminución de la diversidad. Es recomendable que el tamaño de la población sea adecuado y además, que las probabilidades de cruzamiento y mutación sean suficientemente grandes para evitar la convergencia prematura. En el esquema general del algoritmo el operador mutación actúa sobre la población una vez que sobre ésta se han volcado los individuos élite. Esto implica que la élite puede verse sometida a cambios en su estructura que ayudan a evitar la convergencia prematura. Los individuos almacenados en el *buffer* se mantienen sin cambios.

Así como en LG1 los experimentos realizados demostraron una significativa mejora en los resultados al emplear elitismo, en LG2 esto resultó menos obvio. La combinación de estrategia elitista y alta probabilidad de mutación produjo resultados similares a los obtenidos sin emplear elitismo y usando bajas probabilidades de mutación. Sí mejoró, sin embargo, la rapidez de convergencia, obteniendo los mismos resultados en menor tiempo con el empleo del elitismo. Como contrapartida, en ocasiones el algoritmo queda atrapado en óptimos locales debido a una convergencia prematura de la población.

A raíz de esto, el empleo o no de esta característica de LG2 se mantiene como opción, siendo el planificador el que debe decidir su utilización. No se considera recomendable si se realiza una única ejecución de LG2 para el árbol de cortes obtenido en LG1, dado que se corre el riesgo de que el algoritmo converja de manera prematura. Cuando, como es el caso del presente trabajo, se realizan varias ejecuciones de LG2 para el mismo árbol de cortes, la probabilidad de que en todas ellas el algoritmo caiga en un óptimo local disminuye, obteniendo una mejora substancial en los tiempos de cálculo empleando el elitismo.

#### 6.7.4 Búsqueda local en LG2; exploración de ratios

Esta funcionalidad del algoritmo es aplicable en los casos en los que el ratio de la planta es una variable del problema, y se pretende que el algoritmo determine la forma más adecuada del dominio de ubicación. Además, no será aplicable cuando se emplee como ratio de la planta el *ratio recomendado* obtenido en LG1 (ver 6.6.7), dado que en ese caso el ratio se considera fijo para LG2. Se entra en esta etapa de búsqueda local cada vez que se localiza una nueva solución óptima y antes de que ésta se introduzca en la élite.

Como se expuso anteriormente, el ratio de cada solución queda codificado en el último gen del cromosoma que la representa. La variabilidad de la población, en cuanto a ratio de planta se refiere, viene determinada por la actuación del operador mutación sobre dicho último gen de la cadena. El número de alelos que pueden ocupar ese locus es, en sentido estricto, infinito, dado que entre el ratio mínimo y el ratio máximo permitidos para la planta existen infinitos reales válidos. Al implementar informáticamente el método se discretiza dicho intervalo, permitiendo que el alelo pueda tomar sólo determinados valores repartidos regularmente en él. Si se desea una mayor precisión, para lograr que el algoritmo determine con mayor exactitud el ratio de la planta más adecuado, se aumenta el número de muestras del intervalo, aumentando así el conjunto de alelos.

Sin embargo, hacer extremadamente grande este conjunto resulta poco operativo. En su lugar, es preferible emplear un conjunto de alelos menor, es decir, discretizar más groseramente el intervalo de ratios, y luego emplear un procedimiento de refino. Así, al disminuir el número de alelos, es más probable que el algoritmo localice el más adecuado de

ellos para el problema dado. Posteriormente se busca el óptimo en el entorno de dicho ratio.

El procedimiento es el siguiente: supóngase que el intervalo de ratios permitidos es  $[r_{\min}, r_{\max}]$ , y que el intervalo se ha discretizado empleando en la búsqueda un total de  $n$  ratios posibles  $\{r_1, r_2, \dots, r_{r-1}, r_r, r_{r+1}, \dots, r_{n-1}, r_n\}$  repartidos uniformemente en el intervalo. Supóngase que se ha localizado una nueva solución óptima cuyo ratio es  $r_r$  (ver Figura 6.68). Antes de que pase a ocupar la primera posición de la pila élite, se somete a un proceso de búsqueda local haciendo variar su ratio entre  $\{r_{r-1}, r_{r+1}\}$ , muestreando ahora este nuevo intervalo más refinadamente. Se mantiene la cadena que representa al individuo constante, haciendo que el último gen adopte cada uno de los valores del intervalo. El individuo es evaluado con cada uno de los ratios, seleccionando finalmente aquél que proporciona un mayor grado de aptitud. El individuo inicial adopta el nuevo ratio y pasa con él a la pila élite. Al volcar el contenido del *buffer élite* en la población el nuevo ratio pasa a la población, pudiéndose propagar mediante cruzamiento con otros individuos.

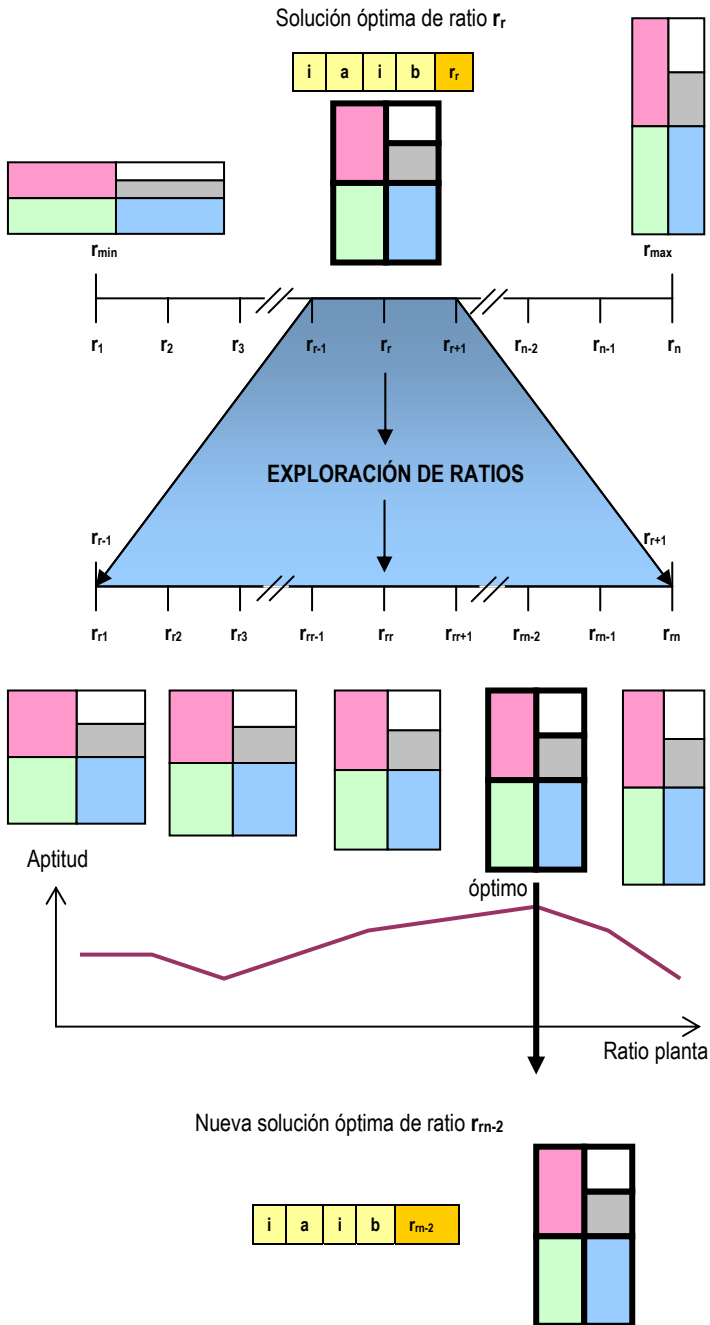


Figura 6.68: Exploración de ratios en LG2.





# 7

## Implementación informática de LAYAGEN G

## 7. IMPLEMENTACIÓN INFORMÁTICA DE LAYAGEN G

### 7.1. Introducción

El algoritmo descrito en el capítulo anterior se implementó en una aplicación informática, mediante programación orientada a objetos con Borland Delphi v.7 bajo entorno operativo Windows. Los objetivos perseguidos en el diseño de la aplicación fueron los siguientes:

- Agrupar en un único software todas las tareas a realizar en la resolución de un problema de distribución en planta mediante el método propuesto: introducción de datos, fijación de parámetros, ejecución de las dos fases del algoritmo, explotación de resultados... facilitando al planificador dichas tareas y agilizando el proceso de experimentación.
- Ofrecer información en tiempo real, gráfica y numéricamente, sobre la evolución de la población y valores de la función objetivo.
- Permitir el cambio de parámetros de ejecución del algoritmo (probabilidades de mutación y cruce, tamaño de la población, activación o desactivación del elitismo y la intensificación de la búsqueda local...) durante la ejecución.
- Implementar una estructura cliente servidor que permita la resolución de problemas en una red de ordenadores.
- Recoger, explotar y almacenar la información y resultados de los experimentos.

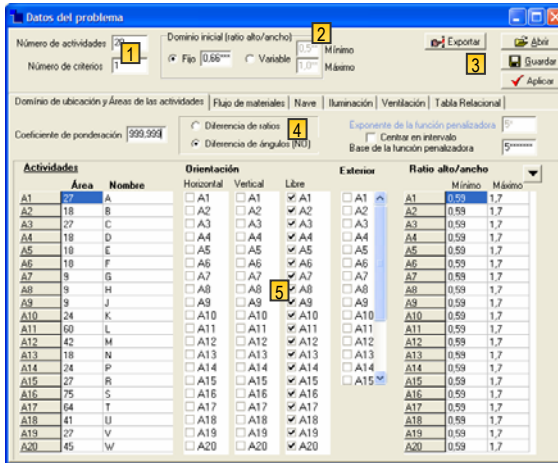
En los siguientes apartados se describe la aplicación informática desarrollada para la realización de la fase experimental del presente trabajo.

### 7.2. Introducción de datos

La introducción de los datos del problema a resolver se realiza en las ventanas mostradas en la Figura 7.1. Para exponer las diversas funcionalidades del software, se han marcado mediante números las diferentes zonas del interfase.

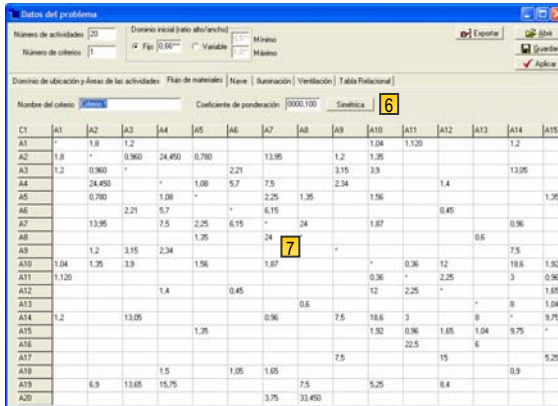
- En la zona **1** se introduce el número de actividades del problema y el número de criterios que se emplearán para evaluar las soluciones.
- En **2** se indica si el dominio de ubicación poseerá un dominio de ratio alto-ancho fijo, o si será variable en un intervalo determinado; además se establecen los valores de dichos límites.
- En **3** es posible guardar en archivos los datos referidos a un problema, cargarlos posteriormente, y generar informes con dicha información.

- En 4 se especifican los coeficientes de ponderación de los diferentes criterios empleados en la evaluación de soluciones y se introducen los coeficientes de penalización geométrica.



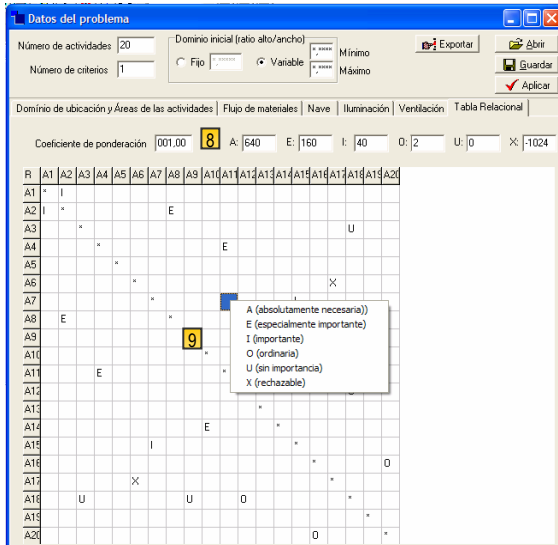
- La zona 5 permite introducir la información referente a la superficie, colocación y forma de las actividades (nombre, área, orientación, necesidad de ser exterior y ratios de forma máximos y mínimos).

- En 6 se indica el coeficiente de ponderación del coste debido al transporte de materiales entre actividades.



- En 7 se introduce la matriz de flujos de transporte.

- En caso de ser necesario emplear la tabla relacional de actividades, en 8 se establecerá la equivalencia cuantitativa de cada una de las relaciones cualitativas entre actividades. Por defecto, las equivalencias son: A=640, E=160, I=40, O=2, U=0, X=-1024.



- En la zona 9 se introducirán las relaciones entre actividades.

### 7.3. Ejecución de LG1

Una vez introducidos los datos del problema a resolver se ejecuta LG1 para localizar el árbol de cortes más adecuado. Previamente, deben especificarse los parámetros de ejecución. Esto se realiza en la pantalla mostrada en la Figura 7.2.

Figura 7.1: Interfaz de introducción de datos del problema.

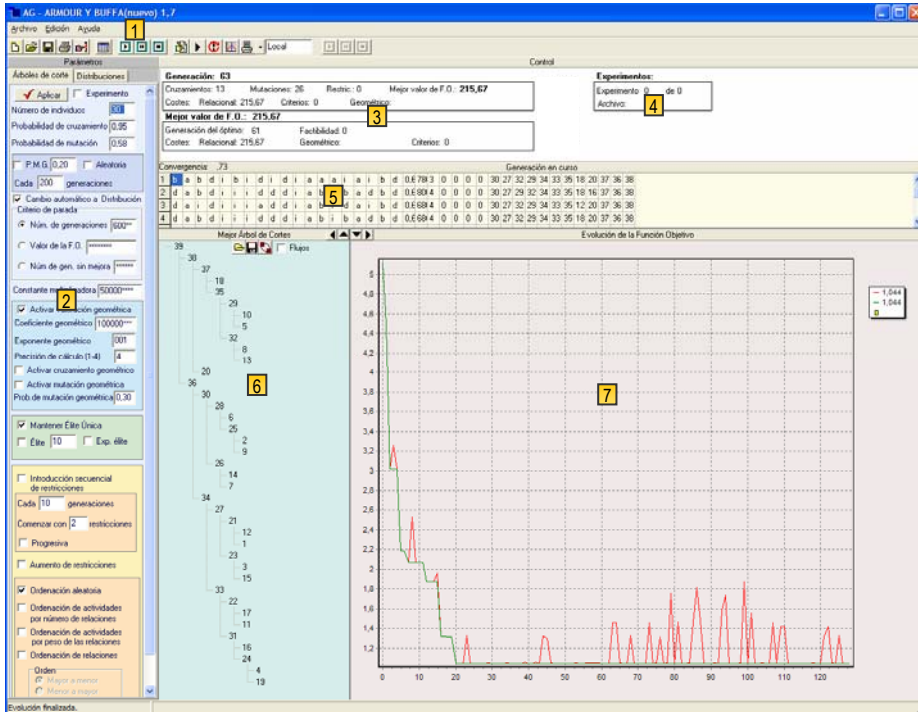


Figura 7.2: Interfase de parametrización y ejecución de LG1.

- En la zona 1 se dispone de una barra de herramientas y un menú que permite acceder a diversas funcionalidades del programa, como la generación e impresión de informes, la realización automatizada de experimentos, guardar o importar datos, o la ejecución en una red de ordenadores.
- La zona marcada como 2, es la destinada a la introducción de los parámetros de ejecución de LG1. Se debe indicar: probabilidades de mutación, cruce e intensificación de la búsqueda, número de generaciones a ejecutar, constantes multiplicadoras de la función objetivo, activación o desactivación del elitismo, tamaño de la élite, etc.
- Una vez establecidos los parámetros se comienza la evolución. El usuario recibe información sobre la ejecución en la zona 3, donde se reflejan datos como los mejores valores de la función objetivo en la actual generación y en el global de la evolución, las valoraciones de las soluciones según cada uno de los criterios de evaluación, la generación actual, etc. En la zona 4 se añade información de interés en el caso de estar ejecutándose un grupo de experimentos automatizados.
- En la zona 5 se representan los cromosomas de los individuos de la población de la generación actual e información sobre el grado de convergencia.
- En 6 se representa el mejor árbol de cortes localizado hasta la generación actual. Mediante los botones que aparecen en la parte superior de dicha zona es posible acceder a ventanas que muestran diversa información sobre el árbol representado. Como ejemplo, en

la Figura 7.4 se muestra la ventana de información sobre los potenciales de adyacencia del árbol de cortes representado.

- Por último, en 7 puede conocerse mediante una gráfica la evolución de la función objetivo. Se representa mediante una línea verde el valor de la función objetivo de la mejor solución localizada hasta el momento, y mediante una línea roja, el valor de la función objetivo de la mejor solución de la población en la generación actual. En caso de emplear una estrategia elitista dichas líneas coinciden, dado que el mejor individuo está siempre presente en la población.

El software permite la variación en tiempo real de los parámetros de ejecución, dando la oportunidad al planificador de intervenir en la evolución cuando lo considere conveniente. En la Figura 7.3 se muestra un ejemplo de la influencia en la evolución de la función objetivo de cambios en la parametrización durante la ejecución. En dicho ejemplo la evolución comienza con una probabilidad de mutación de 0,4 que es aumentada a 0,95 en la generación 450, y disminuida de nuevo a 0,1 en la generación 800. Por último en la generación 865 se activa el elitismo, por lo que a partir de dicha generación coinciden las gráficas verde y roja.




Figura 7.3: Influencia en la evolución de la función objetivo de cambios en la parametrización durante la ejecución.

Potenciales de adyacencia del árbol de cortes																				
A0	A1	A2	A3	A4	A5	A6	A7	A8	A9	A10	A11	A12	A13	A14	A15	A16	A17	A18	A19	A20
A1	*	.18	.56	.24	.1	.24	.24	.1	.18	.1	.32	1	.1	.24	.56	.32	.32	.18	.24	.24
A2	.18	*	.18	.13	.1	.75	.42	.1	1	.1	.18	.18	.1	.42	.18	.18	.18	.18	.13	.24
A3	.56	.18	*	.24	.1	.24	.24	.1	.18	.1	.32	.56	.1	.24	1	.32	.32	.18	.24	.24
A4	.24	.13	.24	*	.08	.18	.18	.08	.13	.08	.42	.24	.08	.18	.24	.75	.42	.13	1	.18
A5	.1	.1	.1	.08	*	.13	.13	.56	.1	1	.1	.1	.56	.13	1	1	.1	.56	.08	.42
A6	.24	.75	.24	.18	.13	*	.56	.13	.75	.13	.24	.24	.13	.56	.24	.24	.24	.24	.18	.32
A7	.24	.42	.24	.18	.13	.56	*	.13	.42	.13	.24	.24	.13	1	.24	.24	.24	.24	.18	.32
A8	.1	.1	.1	.08	.56	.13	.13	*	.1	.56	.1	.1	1	.13	1	.1	.56	.08	.42	.24
A9	.18	1	.18	.13	.1	.75	.42	.1	*	.1	.18	.18	.1	.42	.18	.18	.18	.18	.13	.24
A10	.1	.1	.1	.08	1	.13	.13	.56	.1	*	.1	.1	.56	.13	1	1	.1	.56	.08	.42
A11	.32	.18	.32	.42	.1	.24	.24	.1	.18	.1	*	.32	.1	.24	.32	.56	1	.18	.42	.24
A12	.1	.18	.56	.24	.1	.24	.24	.1	.18	.1	.32	*	.1	.24	.56	.32	.32	.18	.24	.24
A13	.1	.1	.1	.08	.56	.13	.13	1	.1	.56	.1	1	*	.13	1	1	.1	.56	.08	.42
A14	.24	.42	.24	.18	.13	.56	1	.13	.42	.13	.24	.24	.13	*	.24	.24	.24	.24	.18	.32
A15	.56	.18	1	.24	.1	.24	.24	.1	.18	.1	.32	.56	.1	.24	*	.32	.32	.18	.24	.24
A16	.32	.18	.32	.75	.1	.24	.24	.1	.18	.1	.56	.32	.1	.24	.32	*	.56	.18	.75	.24
A17	.32	.18	.32	.42	.1	.24	.24	.1	.18	.1	.32	.1	.24	.32	.56	*	.18	.42	.24	.24
A18	.18	.18	.18	.13	.56	.24	.24	.56	.18	.56	.18	.18	.56	.24	.18	.18	*	.13	.75	.24
A19	.24	.13	.24	1	.08	.18	.18	.08	.13	.08	.42	.24	.08	.18	.24	.75	.42	.13	*	.18
A20	.24	.24	.24	.18	.42	.32	.32	.42	.24	.42	.24	.24	.42	.32	.24	.24	.24	.75	.18	*

Figura 7.4: Información sobre los potenciales de adyacencia de un árbol de cortes.

## 7.4. Ejecución de LG2

Una vez determinado el árbol de cortes adecuado en LG1 se procede a la ejecución de LG2. De manera opcional este cambio se produce de forma automática, transformándose el interfase en el de la Figura 7.5.

- La zona marcada como 1, es la destinada a la introducción de los parámetros de ejecución de LG2.
- En 2 se representa gráficamente mediante un diagrama de bloques la mejor distribución localizada hasta la generación actual a partir del árbol de cortes. Las actividades que incumplen las restricciones geométricas se representan en color rojo.
- La zona 3 permite realizar, de manera manual, modificaciones de las plantas obtenidas. Así, si es necesario por cualquier motivo realizar algún cambio sobre la distribución original para ajustarla a las necesidades reales, es posible conocer los cambios en la valoración de la solución, es decir, cuanto aumenta el coste del transporte de materiales o cuanto varía la calidad geométrica de la solución respecto de la original. Las modificaciones se realizan “pinchando” con el ratón sobre la actividad a recolocar y arrastrándola a su nueva posición.
- Por último, de la misma forma que en LG1, en la zona en 4 se ofrece mediante una gráfica la evolución de la función objetivo.

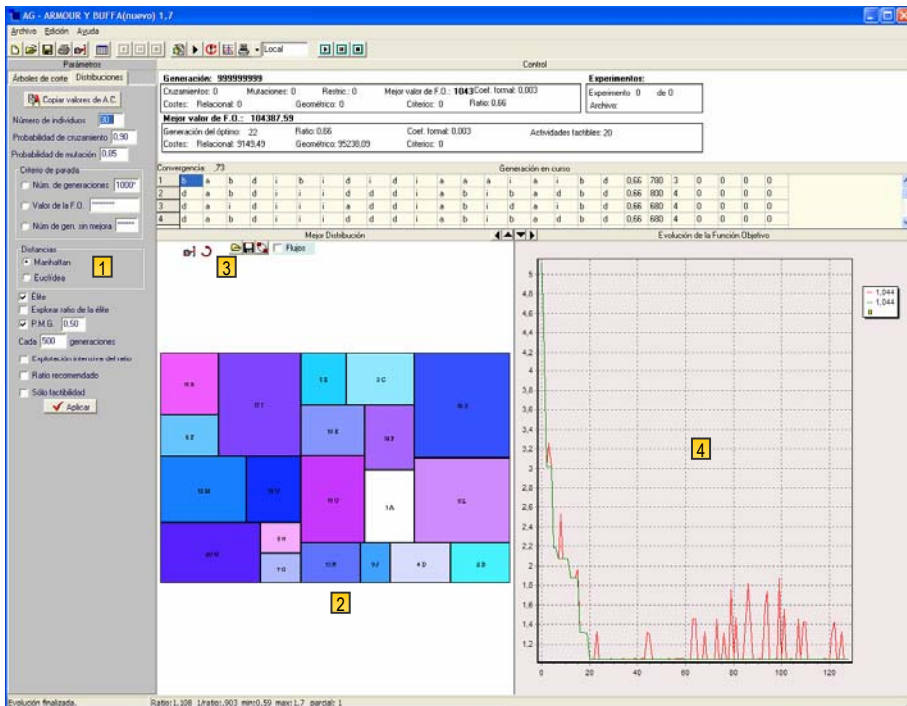


Figura 7.5: Interfase de parametrización y ejecución de LG2.

## 7.5. Automatización del proceso de experimentación

En ocasiones es necesario resolver un número elevado de problemas, o resolver el mismo problema diversas veces con parámetros diferentes. Éste es el caso, por ejemplo, del proceso experimental descrito en el próximo capítulo. Para facilitar esta tarea se introdujo en el software una funcionalidad que permite definir cada uno de los experimentos y que estos sean resueltos de forma automática y sucesiva.

Los parámetros de ejecución, los datos del problema y el número de veces a resolverlo, se especifican en la ventana mostrada en la Figura 7.6. Esta información es almacenada en un archivo. Una vez generados todos los archivos correspondientes a los problemas que se desean resolver, estos se almacenan en una carpeta. El software ejecutará de forma sucesiva todos ellos, almacenando los resultados y gran cantidad de información respecto a la evolución de cada uno.

Figura 7.6: Introducción de datos para la automatización de la resolución de problemas.

Una vez finalizado el proceso de resolución de los problemas es posible visualizar los resultados de cada uno mediante un visor específicamente creado, y que se muestra en la Figura 7.7. En él se puede consultar los árboles de corte, gráficas de las distribuciones obtenidas, los valores medios, máximos y mínimos del coste del flujo de materiales, del incumplimiento de las restricciones geométricas, de las generaciones de aparición de los individuos óptimos, del número de actividades que incumplen los requerimientos

geométricos, etc. Además, es posible generar informes sobre los resultados.

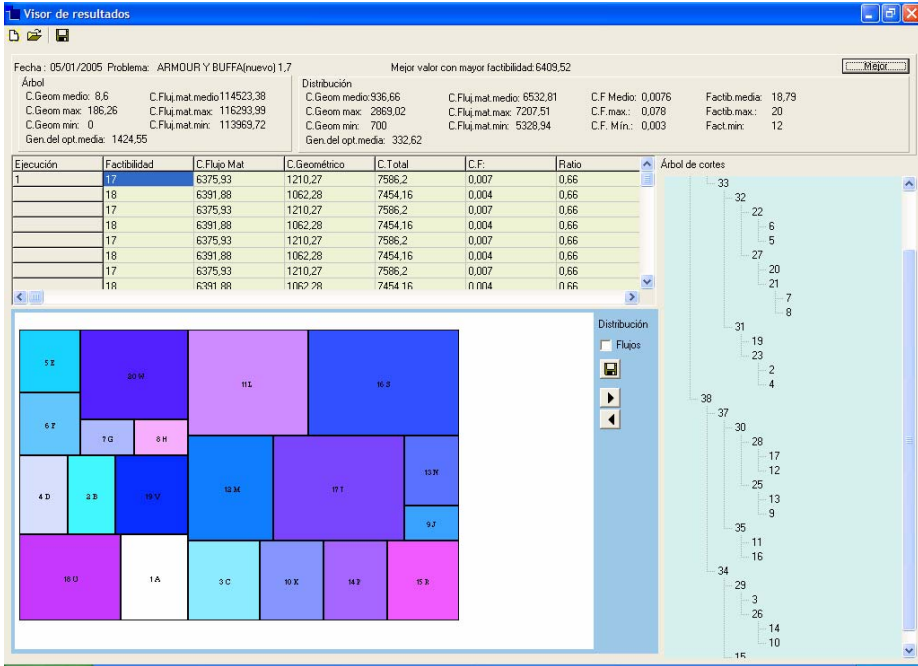


Figura 7.7: Visor de resultados de experimentos automatizados.

## 7.6. Ejecución distribuida en una red de ordenadores

Se dotó a la aplicación desarrollada de capacidad para actuar como servidor de problemas y cliente ejecutor de los mismos en una red de ordenadores. La estructura cliente/servidor implementada está compuesta por un ordenador servidor encargado de organizar el envío de problemas y la recolección de soluciones; un equipo distribuidor, encargado de gestionar el envío de problemas a clientes disponibles; y una serie de equipos cliente que reciben resuelven y devuelven las soluciones de los problemas (Figura 7.8).

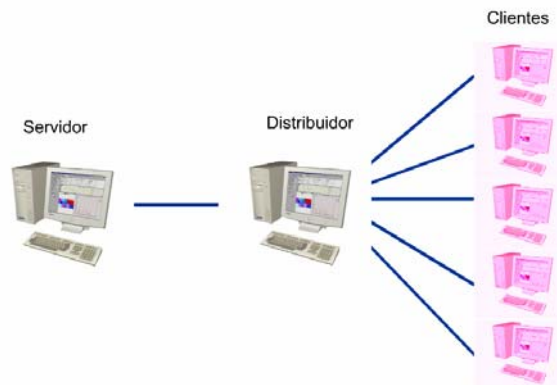


Figura 7.8: Estructura de la red de ejecución distribuida.







# 8

## Validación experimental de la metodología propuesta

## 8. VALIDACIÓN EXPERIMENTAL DE LA METODOLOGÍA PROPUESTA

### 8.1. Introducción

En este capítulo se probará la capacidad del método propuesto en los capítulos precedentes para proporcionar soluciones de elevada calidad a problemas ampliamente estudiados en la bibliografía, lo que permitirá establecer comparaciones de los resultados obtenidos con otros procedimientos, ratificar el cumplimiento de los objetivos planteados al inicio del presente trabajo y validar las hipótesis que le han servido de guía. La validación requiere de algunos experimentos previos dirigidos a definir la correcta parametrización del algoritmo, a determinar la utilidad del empleo de determinadas funcionalidades del mismo (elitismo, búsqueda local, etc), a analizar como influye la inclusión de estas características en los tiempos de ejecución de sus diferentes fases, y a comprobar la eficacia del potencial geométrico del árbol de cortes como parte de la función de aptitud en LG1. Tras ello se aplicará el método propuesto a la resolución de conocidos problemas de la bibliografía, que servirán para validar su capacidad comparando los resultados obtenidos con los de otros métodos muy difundidos.

En resumen, el plan experimental diseñado es el siguiente:

- Un primer conjunto de experimentos se dirigirá a la correcta parametrización del algoritmo, tratando de establecer los valores adecuados de los diferentes parámetros para optimizar los resultados obtenidos.
- Un segundo set de experimentos determinará la influencia de la inclusión de las diferentes funcionalidades del algoritmo sobre los tiempos de ejecución del mismo.
- Tras esto, se aplicará el algoritmo propuesto a la resolución del conocido problema de Armour y Buffa [Armour et al., 63], el problema de Francis y White [Francis et al., 74], y el problema de Kar Yan Tam descrito en [Tam et al., 91], comparando los resultados con los de otros métodos.
- Por último se planteará y resolverá un problema desarrollado específicamente para poner a prueba las características particulares del algoritmo LAYAGEN G

En todos los casos, y sin pérdida de generalidad, los criterios considerados para evaluar las soluciones obtenidas fueron únicamente la minimización de los costes asociados al transporte de materiales entre actividades, y el cumplimiento de las restricciones geométricas.

Dado el carácter no determinista de las técnicas metaheurísticas, es un procedimiento habitual en la bibliografía que cada experimento sea realizado varias veces, obteniendo conclusiones sobre los resultados medios obtenidos, evitando de esta forma que dichas conclusiones obedezcan a resultados circunstanciales especialmente buenos, o substancialmente peores de lo habitual. Esto aumenta la fiabilidad de los resultados a costa de aumentar el tiempo global de cómputo necesario; en este sentido resultó de especial utilidad durante el desarrollo de la experimentación el empleo de una red de ordenadores trabajando en paralelo (Figura 8.1).



*Figura 8.1: Red de ordenadores empleada en la resolución de los problemas de distribución en planta mediante la metodología propuesta.*

Cada uno de los problemas planteados en este capítulo se ha resuelto diez veces manteniendo las mismas condiciones de ejecución y parametrización. En todos los casos se ofrece como resultados los valores medios, máximos y mínimos de los diez experimentos de aquellas variables que se desea medir. El gran volumen de cálculo que esto supone fue afrontado mediante el empleo de una red de 12 ordenadores cliente trabajando en paralelo y de un decimotercer equipo actuando simultáneamente como cliente y servidor de problemas. Los ordenadores estaban equipados con procesadores de 1,8 gigahercios y 1 gigabyte de memoria R.A.M. y en todos ello se ejecutó el software expuesto en el capítulo anterior (actuando como cliente o servidor según el caso).

## **8.2. Parametrización del algoritmo**

El número de parámetros que determinan el funcionamiento de LAYAGEN-G es muy elevado, teniendo que añadir a los habituales de cualquier algoritmo genético los parámetros específicos del método. Esto es más así en cuanto que LAYAGEN-G es un método en dos fases, lo que duplica el número de parámetros a establecer. La adecuada selección de los parámetros para la resolución de un problema determina en gran medida las posibilidades de éxito.

*“This balance, which critically controls the performance of the genetics algorithms, is determined by the right choice of control parameters: the crossover and mutation rates and the population size” [Srinivas et al., 94b].*

La selección correcta de los parámetros no es una tarea trivial, en [Srinivas et al., 94b] se indica que el tema está lejos de ser resuelto. Por ejemplo, existen interacciones evidentes

entre la actuación de los operadores genéticos y el tamaño de la población, que convierten a la parametrización en un complejo problema de optimización no lineal [Grefenstette, 86]. Los parámetros adecuados dependen además fuertemente del tipo de función de aptitud empleada y, por tanto, de las características del caso al que se aplica.

Digalakis y Margaritis [Digalakis et al., 00] realizaron un estudio de la variación del rendimiento de los algoritmos en función de la parametrización establecida, midiendo el rendimiento en la optimización de 14 funciones referencia (benchmark), variando el tamaño de la población, el modo de realizar el reemplazo, la probabilidad de cruce y mutación, el tipo de selección, etc. Este tipo de procedimientos es complejo, y sus resultados no pueden ser generalizados. Si la adecuación de los parámetros depende de la función de aptitud empleada, o del tamaño y características del problema, se hace necesaria una determinación empírica de los parámetros de ejecución para cada caso. Es habitual realizar algunos ensayos previos a la ejecución definitiva de los algoritmos metaheurísticos, observando su funcionamiento bajo diferentes parametrizaciones, determinando, finalmente, los más adecuados para el problema a resolver. No obstante, los algoritmos genéticos suelen proporcionar cierta *versatilidad paramétrica*, es decir, existen unos ciertos intervalos de variación de los parámetros que son aceptables para resolver de manera satisfactoria la mayor parte de los problemas.

Teniendo todo esto en cuenta no se debe tratar de determinar valores óptimos de los parámetros. Lo que se pretende no es buscar valores fijos para estos, sino órdenes de magnitud, intervalos de variación, que deberán ajustarse posteriormente de manera empírica en cada problema.

Los parámetros de LAYAGEN-G se pueden agrupar de la siguiente forma: aquellos que, o bien son comunes a todos los algoritmos genéticos o bien ya existían en LAYAGEN, y los que son propios de LAYAGEN-G. Para los del primer grupo es posible guiarse por las experiencias previas. Para el último grupo la determinación debe ser completamente empírica dado que no existen referencias.

Como ya se comentó en la revisión del estado del arte de los algoritmos genéticos existen dos enfoques respecto a la selección de los parámetros básicos comunes del algoritmo (probabilidad de cruce, de mutación y tamaño de la población), expresados mediante dos sets de parámetros, que proporcionan, de manera general, buenos resultados. El primero, propuesto por De Jong y Spears [De Jong et al., 90] emplea tamaños de población grandes (del orden de 100 individuos) y probabilidades bajas de cruzamiento y mutación ( $P_c=0,6$  ,  $P_m=0,001$ ). El segundo, sugerido en [Grefenstette, 86], propone tamaños de población menores (del orden de 30 individuos), con mayor actividad de los operadores genéticos ( $P_c=0,9$  ,  $P_m=0,01$ ). El primer enfoque disminuye la actividad de los operadores manteniendo la diversidad gracias a una gran población. El segundo actúa a la inversa, una población pequeña que evita la convergencia prematura por la actuación intensiva de los operadores genéticos. Ambas orientaciones proporcionan un papel preponderante a la actividad del operador cruce frente a la mutación. En este trabajo, y como resultado de experiencias previas sobre LAYAGEN (ver [Santamarina, 95]) se optará por la segunda posibilidad.

En la Tabla 8.1 y en la Tabla 8.2 se muestran los parámetros que determinan el comportamiento de LAYAGEN-G. La columna *Rango* de dichas tablas indica el intervalo de

valores en el que, tras la implementación informática del algoritmo, pueden variar los parámetros. Hay que hacer notar que la transformación del algoritmo en un software conlleva necesariamente imponer ciertas limitaciones a los valores que pueden adoptar las diferentes variables. Por ejemplo, el tamaño de la población, de manera teórica, puede variar entre dos e infinito, sin embargo, en la práctica, dicho tamaño vendrá limitado por la memoria disponible para albergar la población y por la necesidad de lograr un tiempo de cálculo razonable. Así pues, en la siguiente tabla, la columna *Rango* indica los intervalos de variación de los parámetros en la implementación informática.

Fase 1		
Acrónimo	Nombre del parámetro	Rango
n	Tamaño de la población	2 - 500
Pc	Probabilidad de cruce	0 - 1
Pm	Probabilidad de mutación	0 - 1
Ng	Número de generaciones	1 - 999.999.999
Cr	Coficiente relacional	1 - 999.999.999
Cg	Coficiente geométrico	1 - 999.999.999
Eg	Exponente geométrico	1 - 999
Pg	Precisión geométrica	1 - 4
	Mutación geométrica	activa / inactiva
Pmg	Prob. de mutación geométrica	0 - 1
	Intensificación de búsqueda	activa / inactiva
Fib	Frecuencia de intensificación	1 - 999.999.999
lib	Intensidad de intensificación	2 - 500
	Aleatoriedad de intensificación	activa / inactiva
	Estrategia elitista	activa / inactiva
le <sub>1</sub>	Intensidad de elitismo	1 - 500
	Intensificación en la élite	activa / inactiva

Tabla 8.1: Parámetros de la primera fase de LAYAGEN-G.

Fase 2		
Acrónimo	Nombre del parámetro	Rango
n	Tamaño de la población	2 - 500
Pc	Probabilidad de cruce	0 - 1
Pm	Probabilidad de mutación	0 - 1
Ng	Número de generaciones	1 - 999.999.999
Cr	Coficiente relacional	1 - 999.999.999
Cg	Coficiente geométrico	1 - 999.999.999
	Métrica	Manhattan -
	Estrategia elitista	activa / inactiva
le <sub>2</sub>	Intensidad de elitismo	1 - 500
	Exploración de ratios	activa / inactiva
	Ratio recomendado en Fase 1	sí / no
Na	Número de ejecuciones por árbol	1-1000
p	Exp. función penalizadora	1-500

Tabla 8.2: Parámetros de la segunda fase de LAYAGEN-G.

Como se ha dicho, la parametrización adecuada depende del tipo de problema a resolver. En los experimentos realizados se eligió el conocido problema de Armour y Buffa [Armour et al., 63], en la versión que se ofrece en [Tate et al., 95]<sup>54</sup>; un problema de 20 actividades con matriz de flujos simétrica que emplea como métrica de la distancia la rectilínea. Su empleo en el estudio de la parametrización de LAYAGEN-G se consideró adecuado por ser éste el problema resuelto en posteriores experimentos para comparar la eficacia de dicho algoritmo frente a otros. Las características detalladas del mismo se describirán más en detalle en apartados posteriores.

En la versión original del problema no se restringe de manera explícita la forma de las actividades, sin embargo, Tate y Smith consideran en su planteamiento que la forma de las mismas debe aproximarse a un cuadrado. Así, encuentran soluciones al problema para diferentes ratios ancho-alto<sup>55</sup> máximos de los departamentos, yendo éstos desde 1000 hasta 1,70667. Las actividades se consideran en todos los casos de orientación libre. En los experimentos descritos posteriormente se hizo variar la restricción geométrica de las actividades desde ratios máximos permitidos de 1,7 hasta ratios de 1,12, mucho más restrictivos que los de Tate y Smith. En la Tabla 8.3 y en la Tabla 8.4 se resumen los datos del problema.

<b>Armour y Buffa</b>	
Número de actividades:	20
Dominio de ubicación:	Fijo
Ratio mínimo del dominio	2/3
Ratio máximo del dominio	2/3

<b>Actividades</b>		
<i>Número</i>	<i>Área</i>	<i>Nombre</i>
1	27	A
2	18	B
3	27	C
4	18	D
5	18	E
6	18	F
7	9	G
8	9	H
9	9	J
10	24	K
11	60	L
12	42	M
13	18	N
14	24	P
15	27	R
16	75	S
17	64	T
18	41	U
19	27	V
20	45	W

Tabla 8.3: Datos del problema de Armour y Buffa.

<sup>54</sup> En la matriz de coste del transporte de materiales original del problema publicada en [Armour et al., 63], existe un error tipográfico tal y como se indica en [Scriabin et al., 75] y en [Huntley et al., 91]. Concretamente, el coste del transporte de materiales de la actividad L a la actividad S es 22,5, sin embargo, el coste del transporte de la S a la L aparece como 0, cuando la matriz debe ser, por definición, simétrica. El valor correcto del coste de transporte de L a S es 22,5.

<sup>55</sup> Esta medida es la inversa a la empleada en este trabajo.



## Coste del transporte de materiales entre actividades

	A	B	C	D	E	F	G	H	J	K	L	M	N	P	R	S	T	U	V	W
A	*	1,8	1,2							1,04	1,12			1,2						
B	1,8	*	0,96	24,45	0,78		13,95		1,2	1,35									6,9	
C	1,2	0,96	*			2,21			3,15	3,9				13,05					13,65	
D		24,45		*	1,08	5,7	7,5		2,34		1,4				1,35			1,5	15,75	
E		0,78			*		2,25	1,35		1,56										
F			2,21	5,7		*	6,15				0,45							1,05		
G		13,95		7,5	2,25	6,15	*	24		1,87				0,96				1,65		3,75
H					1,35		24	*					0,6						7,5	33,45
J		1,2	3,15	2,34					*					7,5			7,5			
K	1,04	1,35	3,9		1,56		1,87			*	0,36	12		18,6	1,92					5,25
L	1,12									0,36	*	2,25		3	0,96	22,5				
M				1,4	0,45					12	2,25	*			1,65		15		8,4	
N								0,6					*	8	1,04	6				
P	1,2		13,05				0,96		7,5	18,6	3		8	*	9,75			0,9		
R					1,35					1,92	0,96	1,65	1,04	9,75	*		5,25			
S											22,5		6			*	12			
T									7,5			15			5,25	12	*		7,5	
U				1,5	1,05	1,65								0,9				*	4,65	
V		6,9	13,65	15,75				7,5		5,25	8,4						7,5	4,65	*	
W							3,75	33,45												*

Tabla 8.4: Coste del flujo de materiales en el problema de Armour y Buffa.

## 8.2.1 Parametrización de LG1

En primer lugar se abordó el estudio de la parametrización del algoritmo de búsqueda del árbol de cortes (LG1). Se realizaron un total de 7 experimentos (denominados E1-1, E1-2, E1-3, E1-4, E1-5, E1-6 y E1-7) en los que sólo se ejecutó LG1, no realizando la búsqueda de la distribución óptima contenida en el árbol encontrado (LG2). Como ya se ha indicado se realizaron un total de 10 ejecuciones de cada experimento, resultando un total de 70 ejecuciones.

### 8.2.1.1 Descripción de los experimentos

En todos los casos se mantuvo constante el valor de los coeficientes relacional y geométrico ( $C_r$  y  $C_g$ ), y el exponente y la precisión geométrica ( $E_g$  y  $P_g$ ). No se empleó la mutación geométrica ni las fases de intensificación de la búsqueda. Sí se activó el elitismo dado que esta estrategia sería empleada en todos los experimentos a realizar posteriormente. La búsqueda local de los individuos élite fue activada inicialmente, aunque en el experimento E1-3 se desactivó para comprobar su influencia en el desempeño del algoritmo.

Un resumen del objetivo de los diferentes experimentos es el siguiente:

- **E1-1:** se establecieron los parámetros en base a lo habitualmente empleado en la bibliografía y a los datos aportados sobre LAYAGEN en [Santamarina, 95]. Para este experimento se fijó en 5000 generaciones la duración de la evolución.
- **E1-2:** los resultados obtenidos en E1-1 pusieron de relieve que la duración de la evolución era excesiva; se fijó en 3500 generaciones la duración de la evolución manteniendo el resto de parámetros. Se pretendía ratificar que la disminución en el número de generaciones no haría empeorar los resultados, logrando,

simultáneamente, un menor tiempo de ejecución.

- **E1-3:** se diseñó para comprobar los efectos del empleo de la intensificación local de la búsqueda en los alrededores de la élite. En este experimento, a diferencia de en el resto, esta característica fue deshabilitada.
- **E1-4:** se buscó comprobar el efecto de un aumento en el tamaño de la población; se incrementó dicho valor de 30 a 50 individuos.
- **E1-5, E1-6 y E1-7:** en estos tres experimentos se hizo variar los valores de las probabilidades de mutación y cruce, para analizar su influencia sobre el comportamiento del algoritmo.

Los parámetros establecidos en cada experiencia se recogen en la Tabla 8.5.

Acrónimo	Nombre del parámetro	E1-1	E1-2	E1-3	E1-4	E1-5	E1-6	E1-7
<b>n</b>	Tamaño de la población	30	30	30	50	30	30	30
<b>Pc</b>	Probabilidad de cruce	0,95	0,95	0,95	0,95	0,95	0,70	0,70
<b>Pm</b>	Probabilidad de mutación	0,80	0,80	0,80	0,80	0,50	0,50	0,30
<b>Ng</b>	Número de generaciones	5000	3500	3500	3500	3500	3500	3500
<b>Cr</b>	Coefficiente relacional	500000	500000	500000	500000	500000	500000	500000
<b>Cg</b>	Coefficiente geométrico	100000	100000	100000	100000	100000	100000	100000
<b>Eg</b>	Exponente geométrico	1	1	1	1	1	1	1
<b>Pg</b>	Precisión geométrica	1	1	1	1	1	1	1
	Mutación geométrica	inactiva	inactiva	inactiva	inactiva	inactiva	inactiva	inactiva
<b>Pmg</b>	Prob. de mutación geométrica	-	-	-	-	-	-	-
	Intensificación de búsqueda	inactiva	inactiva	inactiva	inactiva	inactiva	inactiva	inactiva
<b>Fib</b>	Frecuencia de intensificación	-	-	-	-	-	-	-
<b>lib</b>	Intensidad de intensificación	-	-	-	-	-	-	-
	Aleatoriedad de intensificación	-	-	-	-	-	-	-
	Estrategia elitista	activa	activa	activa	activa	activa	activa	activa
<b>le<sub>1</sub></b>	Intensidad de elitismo	1	1	1	1	1	1	1
	Intensificación en la élite	activa	activa	inactiva	activa	activa	activa	activa

Tabla 8.5: Parámetros empleados en los experimentos E1.

### 8.2.1.2 Exposición y análisis de los resultados de los experimentos

Tras las 10 ejecuciones de cada experimento los resultados obtenidos se resumieron en la Tabla 8.6. De cada ejecución de un experimento se recogió el mejor árbol obtenido (por tanto 10 árboles por experimento), calculándose el coste del flujo de materiales y el coste geométrico medios, máximos y mínimos. Se considera de aquí en adelante que coste de flujo de materiales y coste geométrico son las partes correspondientes de la función objetivo con la que se evalúa el árbol. Recordando que los árboles se evalúan mediante el potencial:

$$P_{ac} = Cg \cdot P_{gac} + Cr \cdot \frac{1}{1 + P_{rac}}$$

donde:

- $P_{ac}$  es el potencial del árbol de cortes;
- $P_{gac}$  es el potencial geométrico del árbol de cortes;
- $P_{rac}$  es el potencial relacional del árbol de cortes;
- $Cg$  y  $Cr$  son los coeficientes de ponderación representativos de la importancia relativa entre el criterio geométrico y relacional respectivamente;

se entenderá por *coste del flujo de materiales*, y así se usará en todo este capítulo, a;

$$Cr \cdot \frac{1}{1 + P_{rac}}$$

mientras que por *coste geométrico* se entenderá:

$$Cg \cdot P_{gac}$$

Se calculó, además, la generación en la que, en promedio, se localizó dicho árbol óptimo en cada experimento. Una exposición detallada de todos los resultados obtenidos puede consultarse en el ANEXO 1.

	E1-1	E1-2	E1-3	E1-4	E1-5	E1-6	E1-7	Media
Coste flujo materiales medio	1174,14	1173,73	1225,2	1195,45	1202,56	1201,74	1231,79	<b>1200,66</b>
Coste flujo materiales máximo	1212,81	1213,83	1433,4	1273,57	1286,28	1377,54	1335,86	<b>1304,76</b>
Coste flujo materiales mínimo	1140,26	1139,08	1149,71	1149,71	1140,26	1153,91	1156,61	<b>1147,08</b>
Coste geométrico medio	0	0	0	0	0	0	0	<b>0</b>
Coste geométrico máximo	0	0	0	0	0	0	0	<b>0</b>
Coste geométrico mínimo	0	0	0	0	0	0	0	<b>0</b>
Generación del óptimo media	1377,3	1406,3	2023,6	1546	1739,7	2018,8	2005,7	<b>1731,06</b>

Tabla 8.6: Resumen de los resultados de los experimentos E1.

El análisis de los datos de la Tabla 8.6 revela una gran uniformidad de los resultados obtenidos, de lo que puede extraerse, como primera conclusión, la elevada robustez del algoritmo frente a variaciones en los parámetros de ejecución. En todos los casos, y para cualquier parametrización establecida el algoritmo logró localizar árboles de corte de coste geométrico cero, capaces, por tanto, de generar distribuciones que observen las restricciones geométricas impuestas en el problema. El análisis del resto de datos se facilita mediante la representación gráfica de la Figura 8.2.

La calidad del mejor árbol de cortes de cada experimento (línea verde), no varía de manera decisiva con la parametrización, siendo la diferencia máxima relativa entre ellos menor del 1,6%. En los valores medios y máximos de coste sí se aprecia un mayor efecto.

En E1-1 se realizaron ejecuciones de 5000 generaciones. De media, el árbol de cortes

óptimo apareció en la generación 1377,3, y el más tardío en la 2966 (esta información detallada puede consultarse en el ANEXO 1). A partir de estos datos se decidió disminuir el número de generaciones a 3500; los resultados del experimento E1-2, que mantiene los parámetros de E1-1 salvo la duración de la evolución, son muy similares a los de éste, lo que demuestra el acierto del cambio.

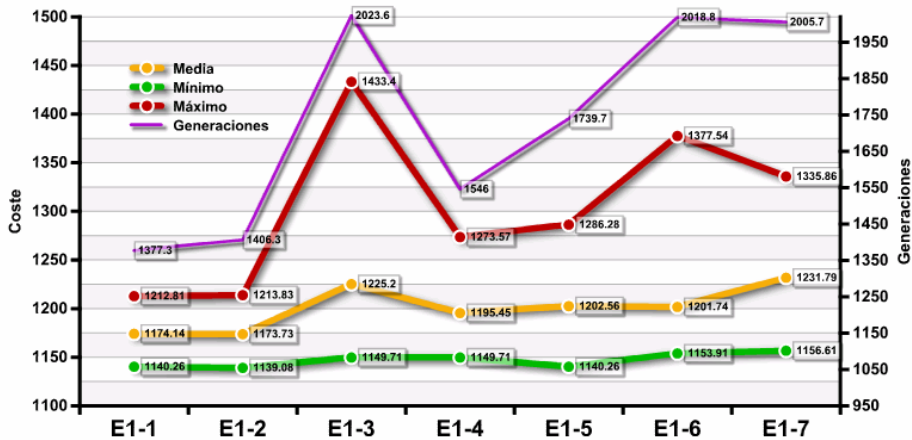


Figura 8.2: Valor del coste del flujo de materiales en los experimentos E1.

La deshabilitación de la búsqueda local en los alrededores de los individuos élite llevada a cabo en E1-3, da como resultado un empeoramiento significativo de los resultados; por una parte el coste medio y la dispersión de los mismos aumentó, por otra, el número medio de generaciones transcurridas hasta la aparición del mejor individuo se hizo significativamente mayor.

El empleo en E1-4 de poblaciones de 50 individuos produce costes medios ligeramente mayores que los de los dos primeros experimentos, mientras que la dispersión de los mismos y el número de generaciones medio hasta la aparición del mejor individuo son significativamente más elevados. Este resultado es difícil de interpretar dado que la mayor diversidad genética que tiene cabida en una mayor población debería significar una ventaja evolutiva. Se puede plantear como hipótesis que el fenómeno es debido la combinación de una gran población y operadores genéticos muy activos, sin embargo, sería necesario un análisis más preciso del comportamiento del algoritmo frente a cambios en el tamaño de la población para poder determinar las causas de este fenómeno.

La disminución progresiva en E1-5, E1-6 y E1-7 de las probabilidades de actuación de los operadores genéticos conlleva un empeoramiento paulatino de los resultados, tanto en cuanto a calidad y dispersión de los árboles obtenidos como al tiempo evolutivo necesario para obtener dichos árboles.

A la vista de estos resultados parece que la combinación de parámetros empleada en el experimento E1-2 resulta la más adecuada. Es necesario recordar que esta conclusión es válida únicamente para el problema empleado en el presente experimento; no obstante, la robustez del algoritmo permite aventurar que servirá también como primera aproximación en

la búsqueda de la parametrización correcta para la resolución de otros problemas.

### 8.2.2 Parametrización de LG2

Se abordó a continuación el estudio de la parametrización del algoritmo de búsqueda de la distribución óptima contenida en árbol de cortes localizado mediante LG1. Se empleó el mismo problema de 20 actividades que en el experimento anterior, aunque en este caso sólo se ejecutó LG2. Los datos del problema están recogidos en la Tabla 8.3 y en la Tabla 8.4. En esta ocasión se endurecieron las restricciones impuestas a la geometría de las actividades, estableciendo un límite máximo del ratio ancho-alto de 1,6 (siendo las actividades de orientación libre). Se realizaron un total de 14 experimentos (denominados genéricamente como E2) en los que siempre se partía del mismo árbol de cortes. Este árbol es el representado en la Figura 8.3; para localizarlo se realizó un experimento previo, escogiendo




Figura 8.3: Árbol de cortes empleado en los experimentos de parametrización de LG2.

de entre los árboles obtenidos uno de coste medio y cuyo potencial geométrico para el ratio de planta del problema fuera 0, es decir, a partir de este árbol es posible obtener distribuciones cuyas actividades cumplan los requisitos geométricos. De nuevo cada experimento se realizó 10 veces, efectuando un total de 140 ejecuciones.

#### 8.2.2.1 Descripción de los experimentos

Tras un periodo de pruebas empleando valores aleatorios, se diseñó el experimento inicial E2-1; el resto de experimentos introduce modificaciones en esa parametrización inicial tratando de evaluar su influencia en el comportamiento de LG-2. En todos los casos se empleó la métrica Manhattan y se consideró que la rigidez de las restricciones geométricas ( $\mu_i$ ) era <sup>56</sup>.

<sup>56</sup> Como ya se indicó al presentar la metodología propuesta,  $\mu_i$  indica la rigidez de las restricciones geométricas de la actividad  $i$ . Existen actividades que necesitan ser asignadas a áreas con formas concretas para poder desarrollarse, mientras que otras ofrecen cierto grado de tolerancia.  $\mu_i$  tomará un valor cercano a 1 si las restricciones son estrictas, y disminuirá proporcionalmente al grado de

Un resumen del objetivo de los diferentes experimentos es el siguiente:

- **E2-1:** se establecieron los parámetros en función de los resultados obtenidos en experimentos previos con parametrización arbitraria. En este experimento se fijó en 3000 generaciones la duración de la evolución.
- **E2-2:** los resultados obtenidos en E2-1 pusieron de relieve que la duración de la evolución era excesiva; se fijó en 1500 generaciones la duración de la evolución manteniendo el resto de parámetros. Se pretendía ratificar que la disminución en el número de generaciones no haría empeorar los resultados, logrando, simultáneamente, un menor tiempo de ejecución.
- **E2-3:** este experimento pretendía comprobar el efecto de una disminución en el tamaño de la población; se decrementó dicho valor de 50 a 30 individuos.
- **E2-4:** se aumentó el valor de la probabilidad de mutación para llevar a cabo una búsqueda más agresiva en el entorno, analizando su influencia sobre el comportamiento del algoritmo.
- **E2-5, E2-6:** se activó el elitismo con intensidad 1 para comprobar su efecto sobre una población sometida a una probabilidad de mutación moderada; en E2-6 el tamaño de la pila élite se aumentó a 3.
- **E2-7:** se aumentaron las probabilidades de mutación y cruce manteniendo la estrategia elitista activa con intensidad 3 para comprobar el efecto de dicha combinación sobre los resultados.
- **E2-8, E2-9:** se hizo variar el exponente de penalización geométrica. Este parámetro pretende aumentar de forma potencial la penalización cuando aumenta el incumplimiento geométrico. El valor empleado hasta el momento era 5, pasando a 10 en E2-8 y a 2 en E2-9.
- **E2-10, E2-11, E2-12, E2-13, E2-14:** los coeficientes relacional y geométrico determinan la importancia relativa del cumplimiento de las restricciones geométricas frente al resto de criterios empleados en la evaluación. En esta serie de experiencias se pretende comprobar la sensibilidad del algoritmo a la variación de dichos coeficientes, y el grado de control que puede ejercerse sobre el cumplimiento de las restricciones geométricas. El valor del coeficiente geométrico se mantuvo constante e igual a 1000, mientras que el relacional fue aumentando desde 0,1 hasta 100.

En la Tabla 8.7 se resumen los parámetros empleados en cada uno de los experimentos.

---

tolerancia en la forma del área asignada a la actividad. En adelante, y si no se menciona lo contrario, se considerará que  $\mu_i=1; \forall i$ .

Acró.	Nombre del parámetro	E2-1	E2-2	E2-3	E2-4	E2-5
n	Tamaño de la población	50	50	30	30	30
Pc	Probabilidad de cruce	0,8	0,8	0,8	0,8	0,8
Pm	Probabilidad de mutación	0,3	0,3	0,3	0,6	0,6
Ng	Número de generaciones	3000	1500	1500	1500	1500
Cr	Coefficiente relacional	0,1	0,1	0,1	0,1	0,1
Cg	Coefficiente geométrico	1000	1000	1000	1000	1000
	Métrica (Manhattan/euclídea)	Manhattan	Manhattan	Manhattan	Manhattan	Manhattan
	Estrategia elitista	inactiva	inactiva	inactiva	inactiva	activa
le <sub>2</sub>	Intensidad de elitismo	----	----	----	----	1
	Exploración de ratios	----	----	----	----	----
	Ratio recomendado en Fase 1	----	----	----	----	----
Na	Número de ejec. por árbol	10	10	10	10	10
p	Exp. función penalizadora	5	5	5	5	5

Acró.	Nombre del parámetro	E2-6	E2-7	E2-8	E2-9	E2-10
n	Tamaño de la población	30	30	30	30	30
Pc	Probabilidad de cruce	0,8	0,9	0,9	0,9	0,9
Pm	Probabilidad de mutación	0,6	0,8	0,8	0,8	0,8
Ng	Número de generaciones	1500	1500	1500	1500	1500
Cr	Coefficiente relacional	0,1	0,1	0,1	0,1	1
Cg	Coefficiente geométrico	1000	1000	1000	1000	1000
	Métrica (Manhattan/euclídea)	Manhattan	Manhattan	Manhattan	Manhattan	Manhattan
	Estrategia elitista	activa	activa	activa	activa	activa
le <sub>2</sub>	Intensidad de elitismo	3	3	3	3	3
	Exploración de ratios	----	----	----	----	----
	Ratio recomendado en Fase 1	----	----	----	----	----
Na	Número de ejec. por árbol	10	10	10	10	10
p	Exp. función penalizadora	5	5	10	2	5

Acró.	Nombre del parámetro	E2-11	E2-12	E2-13	E2-14
n	Tamaño de la población	30	30	30	30
Pc	Probabilidad de cruce	0,9	0,9	0,9	0,9
Pm	Probabilidad de mutación	0,8	0,8	0,8	0,8
Ng	Número de generaciones	1500	1500	1500	1500
Cr	Coefficiente relacional	5	20	50	100
Cg	Coefficiente geométrico	1000	1000	1000	1000
	Métrica (Manhattan/euclídea)	Manhattan	Manhattan	Manhattan	Manhattan
	Estrategia elitista	activa	activa	activa	activa
le <sub>2</sub>	Intensidad de elitismo	3	3	3	3
	Exploración de ratios	----	----	----	----
	Ratio recomendado en Fase 1	----	----	----	----
Na	Número de ejec. por árbol	10	10	10	10
p	Exp. función penalizadora	5	5	5	5

Tabla 8.7: Parámetros empleados en los experimentos E2.

### 8.2.2.2 Exposición y análisis de los resultados de los experimentos

Tras las 10 ejecuciones de cada experimento los resultados obtenidos se resumieron en la Tabla 8.8. De cada ejecución de un experimento se recogió la mejor distribución (por tanto 10 distribuciones por experimento), calculándose el coste del flujo de materiales y el coste geométrico medios, máximos y mínimos. Se calculó, además, la generación en la que, en promedio, se localizó dicha distribución en cada experimento. Una exposición detallada de

los mismos puede consultarse en el ANEXO 1.

Los valores del coste del flujo de materiales se calculan para las 10 distribuciones de cada experimento. Es necesario resaltar que no en todas ellas las áreas asignadas a todas las actividades cumplen los requisitos geométricos impuestos (ratio ancho-alto en el intervalo [0,625 , 1,6]). Así pues, como información complementaria, en la primera fila de la Tabla 8.8 se indica el coste del flujo de materiales de la mejor de las distribuciones obtenidas en el experimento correspondiente, entendiendo por *mejor* distribución, a aquella que con un mayor número de actividades que cumplen los requerimientos geométricos (actividades factibles), posee un menor coste por flujo de materiales.

Recordando que la función evaluadora de LG2 es

$$F = C_r \sum_{i=1}^n \sum_{j=1}^n d_{ij} \cdot \left[ \pm \sum_{u=1}^k \alpha_u \cdot f_{u,ij} \right] + \frac{C_g}{g_c + 1} \cdot \sum_{i=1}^n (\mu_i \cdot l_i + 1)^p$$

donde:

**C<sub>r</sub>**, **C<sub>g</sub>**: coeficientes de ponderación de la importancia relativa entre los criterios relacionales y geométricos.

**d<sub>ij</sub>**: distancia entre los centros de gravedad de las actividades i y j.

**k**: número de criterios relacionales contemplados.

**α<sub>u</sub>**: importancia relativa del criterio u\_ésimo respecto al resto de criterios relacionales.

**f<sub>u,ij</sub>**: valor de la *intensidad relacional* de las actividades i y j bajo el criterio u\_ésimo.

**l<sub>i</sub>**: penalización por el incumplimiento de las restricciones geométricas de la actividad i.

**μ<sub>i</sub>**: rigidez de las restricciones geométricas impuestas a la actividad i. Toma valores entre 0 y 1.

**p**: exponente de la penalización geométrica, parámetro que toma valores entre 1 e infinito que pretende aumentar de forma potencial la penalización cuando aumenta el incumplimiento geométrico.

**g<sub>c</sub>**: número de actividades en la distribución actual que cumplen con las restricciones geométricas del problema.

En la Tabla 8.8 y en adelante se entiende por *coste geométrico* de la distribución a:

$$\frac{\sum_{i=1}^n (\mu_i \cdot l_i + 1)^p}{g_c + 1}$$

y por *coste relacional* o *coste del flujo de materiales* en el caso de no existir otro criterio a:

$$\sum_{i=1}^n \sum_{j=1}^n d_{ij} \cdot \left[ \pm \sum_{u=1}^k \alpha_u \cdot f_{u,ij} \right]$$

Cuando se hable de *costes ponderados* (como en las tablas del ANEXO 1), se estará refiriendo a las expresiones anteriores multiplicadas por los correspondientes coeficientes de ponderación (relacional y geométrico).



	E2-1	E2-2	E2-3	E2-4	E2-5	E2-6	E2-7
Coste flujo materiales distribución óptima / actividades factibles	8237,5 / 20	8299,40 / 20	8365,20 / 20	8597,70 / 20	8103,70 / 20	8103,70 / 20	8103,70 / 20
Coste flujo materiales medio	8283,8	8422,1	8593,22	9308,9	7810,1	8003,9	8024,7
Coste flujo materiales máximo	9411,1	9565,6	10451,1	11479,6	8228,6	8228,6	8420,5
Coste flujo materiales mínimo	7321,9	7622,8	7475,9	8330,4	7076,3	7622,8	7673,8
Coste geométrico medio	1,02	1,34	1,50	1	1,09	1,01	1,2
Coste geométrico máximo	1,26	2,09	2,74	1,26	1,26	1,18	2,06
Coste geométrico mínimo	0,95	0,95	0,95	0,95	0,95	0,95	0,95
Nº medio de actividades válidas	18,9	16,9	15,8	19,2	18,1	19,1	18
Nº máximo de actividades válidas	20	20	20	20	20	20	20
Nº mínimo de actividades válidas	16	12	10	17	16	17	12
Generación del óptimo media	1064,1	1146,6	899,2	849,1	633,8	330,5	599

	E2-8	E2-9	E2-10	E2-11	E2-12	E2-13	E2-14
Coste flujo materiales distribución óptima / actividades factibles	8103,70 / 20	8103,70 / 20	7732,15 / 19	7331,39 / 15	5653,02 / 8	4298,23 / 5	4298,23 / 5
Coste flujo materiales medio	8129	8091,9	7404,22	6928,92	5122,67	4569,98	4359,72
Coste flujo materiales máximo	8416	8416	7732,15	7331,39	5653,02	5270,42	5225,12
Coste flujo materiales mínimo	7732,2	7673,8	7076,29	6828,30	4734,56	4298,23	2677,30
Coste geométrico medio	0,97	1,03	1,13	1,84	20,53	27,16	46,71
Coste geométrico máximo	1,02	1,69	1,26	2,08	29,66	29,67	204,64
Coste geométrico mínimo	0,95	0,95	1,00	1,78	13,35	24,78	24,77
Nº medio de actividades válidas	19,7	19,1	17,5	14,2	6,2	4,5	3,9
Nº máximo de actividades válidas	20	20	19	15	8	5	5
Nº mínimo de actividades válidas	19	12	16	14	4	4	0
Generación del óptimo media	856,5	381,1	277	287,2	409	363,9	253,4

Tabla 8.8: Resumen de los resultados de los experimentos E-2.

Para facilitar el análisis de los resultados obtenidos se representan gráficamente en la Figura 8.4, en la Figura 8.5 y en la Figura 8.6.




Figura 8.4: Coste del flujo de materiales de los experimentos E-2 y número de actividades factibles de las soluciones óptimas. 309




Figura 8.5: Actividades factibles y coste geométrico en los experimentos E-2.




Figura 8.6: Generación de aparición del óptimo en los experimentos E-2.

A la vista de los resultados, LG2 resulta robusto y, en cierta medida, poco afectado por variaciones ligeras de los parámetros de ejecución. En el ANEXO 1 se muestra que, en muchos casos, las soluciones obtenidas son iguales en experimentos diferentes. Dentro de las 10 ejecuciones de un mismo experimento esto sucede con cierta frecuencia; por ejemplo, en el experimento E2-9 se obtiene la misma solución en 8 de las 10 ejecuciones (la solución se muestra en la Figura 8.7; se considera la misma solución a distribuciones que son simétricas entre sí o si una es el resultado de un giro de la otra); esa misma solución aparece 7 veces en E2-8, 5 en E2-7, 6 en E2-6 y 3 en E2-5. Se recuerda que se está entendiendo por mejor solución a aquella de mínimo coste asociado al flujo de materiales cuyas actividades cumplan los requerimientos geométricos.

Podría considerarse que este comportamiento es el resultado de una convergencia prematura del algoritmo hacia un óptimo local, sin embargo, los experimentos cuya

parametrización restringe menos la búsqueda no han logrado obtener soluciones mejores que la representada en la Figura 8.7 incluso con tiempos de ejecución más prolongados. Podría aventurarse que esta solución es un óptimo global dentro del subespacio de distribuciones determinado por el árbol de cortes empleado, o al menos un sub-óptimo de especial calidad. Lo que si es posible afirmar es que el resultado de LG2 viene fuertemente determinado por el árbol de cortes obtenido en LG1, por lo que es conveniente emplear una mayor cantidad de esfuerzo y recursos en la primera fase de LAYAGEN. Una vez determinado un buen árbol de cortes no resultará difícil localizar una buena distribución a partir de él.




Figura 8.7: Mejor solución obtenida en los experimentos E-2. El coste asociado al flujo de materiales entre las actividades es 8103,7.

Como se indicó al inicio de este apartado el potencial geométrico del árbol de cortes empleado en los experimentos E-2 era nulo para el ratio de planta del problema. Esto significa que es posible localizar distribuciones cuyas actividades cumplan los requerimientos geométricos. Observando la Figura 8.5 puede apreciarse que el número medio de actividades factibles (geoméricamente válidas) de las mejores soluciones de cada ejecución oscila entre 16,9 y 19,7 en los 9 primeros experimentos, y en todos ellos se localizaron distribuciones con todas las actividades factibles. En el caso extremo, el experimento E2-8 obtuvo 7 soluciones con todas las actividades factibles y 3 con 19 actividades factibles. En los experimentos E2-10, E2-11, E2-12, E2-13 y E2-14, el número de actividades factibles fue disminuyendo paulatinamente debido al mayor peso otorgado al criterio relacional frente al geométrico.

En la Figura 8.6 se aprecia que la generación media en la que aparece el individuo óptimo en el experimento E2-1 fue 1064,1, y en el ANEXO 1 se comprueba que, como máximo, dicho óptimo apareció en la generación 1498. A la vista de esta circunstancia se disminuye el tiempo de evolución de 3000 a 1500 generaciones en E2-2. Los resultados de E2-2 no varían significativamente respecto de los de E2-1, lo que refrenda el cambio

realizado.

La modificación introducida en E2-3, disminuyendo el tamaño de la población de 50 a 30 individuos, provoca un ligero aumento de la dispersión de los resultados, fundamentalmente del coste geométrico de las soluciones. Esta pérdida de robustez se compensa, no obstante, por la sensible disminución del tiempo de ejecución del algoritmo debido al menor tamaño de la población. Asimismo, el número de generaciones necesario para la localización del óptimo disminuye.

Si la disminución del tamaño de la población provocó un aumento de la dispersión de los costes geométricos, el aumento de la probabilidad de mutación llevado a cabo en E2-4 provocó un empeoramiento del coste del flujo de materiales, tanto en valores relativos como en dispersión. Estos problemas se solucionaron con la activación, en E2-5, de la estrategia elitista, que mejora sensiblemente los resultados en cuanto a coste del transporte de materiales manteniendo una adecuada geometría. Asimismo el tiempo de evolución necesario disminuye muy por debajo de los requeridos en los experimentos anteriores.

En E2-6 se incrementa el tamaño de la élite, de 1 a 3 individuos. Como resultado se mantiene prácticamente sin cambios el coste de transporte de materiales, disminuye la dispersión de los costes geométricos y se produce una drástica disminución de la generación media de aparición del individuo óptimo (Figura 8.6). Al aumentar las probabilidades de actuación de los operadores genéticos en el experimento E2-7, no se produjeron cambios significativos en los resultados referidos al coste del transporte de materiales, aunque la calidad geométrica de las soluciones y el tiempo de evolución necesario aumentaron.

Las modificaciones de los valores del exponente de penalización geométrica de los experimentos E2-8 y E2-9, no influyeron de manera significativa en los resultados referidos al coste del transporte de materiales. Sin embargo, la calidad geométrica de los resultados y el tiempo de evolución sí se vieron profundamente afectados. Al aumentar la penalización por el incumplimiento de las restricciones geométricas en E2-8 se obtuvieron soluciones con elevada calidad formal. Como ya se ha indicado, en este experimento se obtuvieron 7 soluciones con todas las actividades factibles y 3 con 19 de las 20 actividades factibles, y el coste geométrico medio fue el más bajo de todos los obtenidos. Como contrapartida, el tiempo medio de evolución hasta la aparición del individuo óptimo se incrementó de manera ostensible. En el experimento E2-9 la disminución de la penalización provocó que las soluciones obtenidas tuvieran un coste geométrico peor que en el experimento E2-10, pero no significativamente más alto que en los primeros experimentos. El número de generaciones hasta la aparición del individuo óptimo disminuyó a niveles parecidos a los del experimento E2-6.

Como se aprecia en estos experimentos, existe una elevada robustez paramétrica en LG2 que hace innecesario un ajuste extremadamente fino de los parámetros del algoritmo. Sin embargo, los resultados de los experimentos E2-10, E2-11, E2-12, E2-13 y E2-14, en los que se modificó el peso de los criterios empleados para la evaluación de las distribuciones, fue sensiblemente diferente al resto, el número de actividades factibles fue disminuyendo paulatinamente debido al mayor peso otorgado al criterio relacional frente al geométrico.

Se concluye que los coeficientes de ponderación de los criterios (**Cr** y **Cg**) deben escogerse con especial cuidado. En los 9 experimentos iniciales se emplearon 0,1 y 1000 respectivamente. Estos valores dan una especial importancia al criterio geométrico y las

distribuciones obtenidas en estos experimentos cumplen las restricciones del problema. En el experimento 10 se incrementó  $C_r$  a 1, resultando que ninguna distribución de las obtenidas cumplía plenamente las restricciones, aunque el número medio de actividades factibles en las soluciones se mantuvo elevado (17,5) y ninguna tuvo menos de 16 actividades factibles. Conforme se aumenta  $C_r$  aumenta el coste geométrico de las distribuciones (Figura 8.5), disminuye el número de actividades factibles y disminuye el coste del flujo de materiales (Figura 8.4). El bajo peso relativo del criterio geométrico, permite que las áreas de las actividades de las distribuciones resultantes adopten formas esbeltas que minimizan la distancia entre los centros de gravedad. En la Figura 8.8 se muestra la solución de menor coste relacional obtenida; se dio en la tercera ejecución del experimento E2-14 (ver ANEXO 1) y coincide, como es lógico, con la de mayor coste geométrico dado que ninguna de las actividades cumple los requisitos geométricos <sup>57</sup>. Una representación gráfica de los resultados de todos los experimentos puede consultarse en la Figura 8.9 y en la Figura 8.10.




Figura 8.8: Solución de mínimo coste relacional y máximo coste geométrico. El coste asociado al transporte de materiales es 2677.3

En estos experimentos el número de generaciones necesarias para la aparición del individuo óptimo es pequeño en comparación con los casos anteriores (Figura 8.6), debido a que la relajación del criterio geométrico facilita la localización rápida de la distribución que minimiza el coste asociado al flujo de materiales.

En conclusión, mediante la asignación de valores a  $C_r$  y  $C_g$  se posee un elevado control de la geometría de la solución obtenida, estos parámetros se debe escoger con cierta precaución, dado que una inadecuada selección puede provocar, bien soluciones no implementables como la de la Figura 8.8, bien una elevada restricción de la evolución que induzca la convergencia prematura en óptimos locales que, aún cumpliendo los requerimientos geométricos, sean ineficientes respecto al resto de criterios considerados.

Los experimentos E2 han permitido conocer la influencia de cada parámetro sobre el comportamiento de LG2. Como conclusión general, y a la vista de estos resultados, parece que una combinación de parámetros similar a las empleadas en los experimento E2-5 ó E2-6 resultará la más adecuada para la resolución de problemas de características similares al empleado. Es necesario recordar que en realidad las conclusiones obtenidas son válidas únicamente para el problema empleado en el presente experimento; no obstante, la robustez del algoritmo permite aventurar que servirá también como primera aproximación en la búsqueda de la parametrización correcta para la resolución de otros problemas, y así se

<sup>57</sup> En adelante, en las figuras que representen distribuciones, se escogerán colores blanco, azulados y violáceos para las actividades que cumplen las restricciones geométricas, y rojo para aquellas que las incumplen.

demonstró en las sucesivas experiencias realizadas. Se puede concluir, además, que la correcta selección de **Cr** y **Cg** hará necesario una serie de pruebas iniciales antes de afrontar un nuevo problema.



Figura 8.9: Mejores soluciones obtenidas en los experimentos E2 (I).

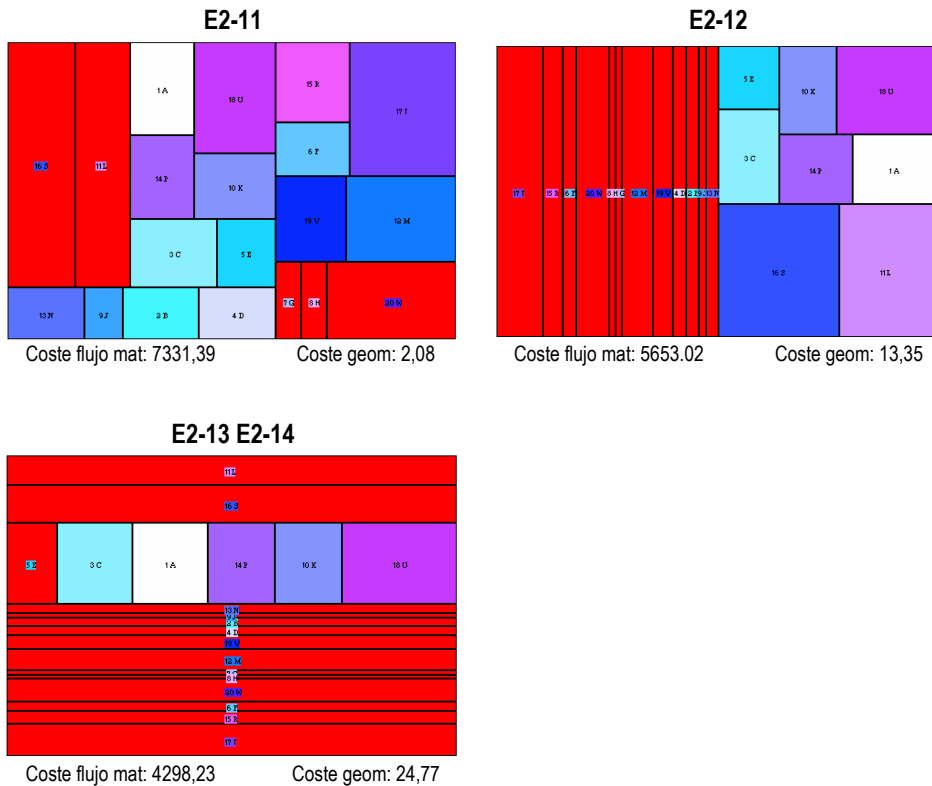


Figura 8.10: Mejores soluciones obtenidas en los experimentos E2 (VII).

### 8.3. Análisis de los tiempos de ejecución de LG1

#### 8.3.1 Introducción

En LAYAGEN-G se han introducido funcionalidades que requieren un intensivo proceso de cálculo, un elevado consumo de recursos computacionales, y por lo tanto, de tiempo de proceso. El tiempo empleado en la resolución de un problema sirve para determinar la eficiencia del método de resolución empleado. El aumento de la capacidad de proceso de los equipos informáticos permite aumentar la complejidad de los algoritmos, sin elevar excesivamente los tiempos de cálculo respecto a los requeridos por procedimientos anteriores en equipos más antiguos. El desarrollo de un algoritmo que, al aumentar su complejidad, obtenga soluciones mejores a un tipo de problema, no debe dejar de lado el control de los tiempos de cálculo necesarios para alcanzar soluciones aceptables. En este apartado se analizarán los tiempos de cálculo requeridos por LAYAGEN-G.

Existen tres problemas básicos en la medición del consumo de tiempo cálculo de un

algoritmo:

**La programación:** un algoritmo debe implementarse en código comprensible por el equipo informático que lo ejecutará. Eso implica transformar el diagrama de flujo que lo representa en una serie de líneas de códigos y comandos cuya adecuación dependerá de la pericia y conocimientos del programador. Una implementación inadecuada del algoritmo puede aumentar en gran medida los requerimientos de tiempo debido a cálculos redundantes o innecesarios, empleo de tipos de variables poco optimizadas o un flujo del programa innecesariamente complejo.

Además, y como es el caso de este trabajo, es difícil separar el algoritmo en sí de otras actividades que el ordenador debe realizar necesariamente, como mostrar al planificador información sobre el desarrollo de la evolución en forma de valores o gráficos. Es decir, además de emplear recursos y tiempo en los cálculos propios del algoritmo, deben emplearse en interactuar con el usuario. En la Figura 8.37 se muestra el interfaz de usuario de la implementación informática de LG2. En ella el usuario recibe información sobre la evolución del algoritmo y sobre la geometría y costes de la mejor solución encontrada hasta el momento. La representación gráfica de las curvas de la función objetivo o de la distribución en planta de las actividades, consume tiempo de proceso que no es propiamente del algoritmo.

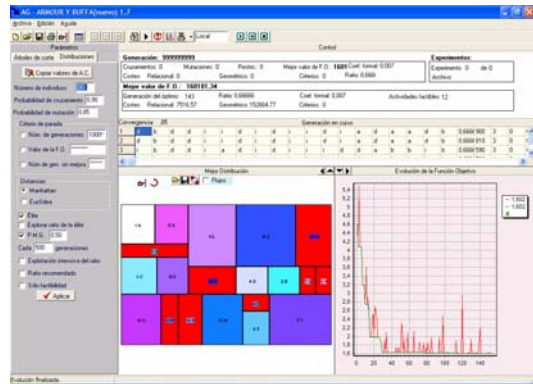


Figura 8.11: Interfaz de usuario empleado en la implementación informática de LG2.

Como caso extremo, la medición los tiempos de cálculo se realiza mediante la introducción en el código de mecanismos de registro. Esto supone a su vez un consumo adicional de tiempo y, por lo tanto, una desvirtuación de los datos.

**El equipo de cálculo:** un mismo algoritmo implementado de la misma forma empleará tiempos de proceso diferentes si se ejecuta en equipos con diferentes características. Son muchas las particularidades del equipo que pueden influir: disponibilidad de memoria de acceso aleatorio, velocidad del procesador, velocidad de acceso a la memoria, disponibilidad de varios procesadores, etc. Esto es más así si el cálculo se realiza en una red de ordenadores, caso en el que incluso el tipo y estado de la red puede hacer variar los tiempos de un caso a otro.

**La aleatoriedad inherente de los algoritmos genéticos:** la evolución del algoritmo posee una fuerte componente aleatoria (en la aplicación de los operadores genéticos fundamentalmente), lo que provoca que los tiempos de ejecución varíen de una ejecución a otra. Este problema puede solventarse mediante el empleo de múltiples mediciones y la obtención de valores medios.

Teniendo presente lo anterior, es necesario precisar que las medidas de tiempos que a continuación se expondrán se refieren más a la implementación informática del algoritmo



realizada en este trabajo que al algoritmo en sí. Así pues, lo que se pretende aquí es realizar un análisis relativo de los tiempos consumidos entre las diferentes fases de la ejecución del algoritmo, entendiendo como tal al programa informático implementado, y conocer qué incrementos supone la activación de cada una de las funcionalidades de las que se ha dotado al algoritmo.

### 8.3.2 Descripción de los experimentos

El experimento se desarrolló sobre el problema de Armour y Buffa de 20 actividades cuyos datos han sido expuestos anteriormente. Se pretendió analizar la repercusión en el tiempo de ejecución de la introducción sobre el *algoritmo básico* de elementos como el cálculo del potencial geométrico del árbol de cortes, la intensificación de la búsqueda en el entorno de las soluciones, el elitismo y la búsqueda en el entorno de la élite, la mutación geométrica y el cruce tal y como se define en LG1, o la consideración de un dominio de la planta variable en un intervalo. Se entiende aquí por *algoritmo básico*, al algoritmo sin las funcionalidades antes mencionadas, en el que el cruce es monopunto estándar sin creación de una lista de posibles puntos de cruce, la mutación geométrica no actúa, y la función evaluadora no realiza el cálculo del potencial geométrico del árbol de cortes. Los cálculos se llevaron a cabo sobre evoluciones de 500 generaciones de poblaciones de 30 individuos, con  $P_c=0,9$ ,  $P_m=0,6$ . Estos parámetros son válidos tanto para LG1 como para LG2.

Como se verá en el apartado siguiente, los experimentos se centraron sobre LG1, dado que el tiempo requerido por LG2 es mucho menor que el necesario para la primera fase. Se realizaron 6 experimentos diferentes sobre LG1 que fueron repetidos 10 veces cada uno. En el primero se ejecutó el que se ha denominado *algoritmo básico*. En el segundo se incluyó el cálculo del potencial geométrico del árbol de cortes en la función evaluadora (la precisión geométrica empleada fue 4). En el tercero se introdujo el mantenimiento de las soluciones élite y la intensificación de la búsqueda en los alrededores de dichas soluciones (el tamaño del conjunto de soluciones élite fue 4). En el cuarto se activó la intensificación local de la búsqueda cada 250 generaciones (lo que supone dos procesos de intensificación en el total de 500 generaciones) sobre 5 individuos. En el experimento 5 se introdujo la mutación geométrica y el cruce con lista de puntos de cruce. Por último, en el experimento 6, se consideró que el ratio de la planta podía variar en el intervalo  $[0,5, 1]$ .

El equipo empleado fue un pequeño ordenador con procesador de 1 GHz, y 256 Mb de memoria RAM.

Experimento	1	2	3	4	5	6
Valoración geométrica	×	✓	✓	✓	✓	✓
Explotación élite	×	×	✓	✓	✓	✓
Intensificación	×	×	×	✓	✓	✓
Cruce y mutación geométrica	×	×	×	×	✓	✓
Dominio variable	×	×	×	×	×	✓

Tabla 8.9: Datos de los experimentos para la medición de tiempos.

### 8.3.3 Resultado de los experimentos

Sobre LG2 se realizaron tres experimentos. El primero de ellos sobre el algoritmo base, el segundo activando la estrategia elitista y el tercero activando, además, la intensificación

local de la búsqueda sobre 5 individuos cada 250 generaciones. Los resultados se ofrecen en la Figura 8.12. Como puede observarse, las variaciones producidas por la introducción de los diferentes elementos en la ejecución son pequeñas. Además, en la realización de los diversos experimentos se comprobó que, de media, y cuando en LG1 se emplean funcionalidades como el elitismo y la intensificación, LG2 supone un 13,41% del tiempo de ejecución de LAYAGEN G, mientras que LG1 representa un 86,59%.




Figura 8.12: Tiempos de ejecución de LG2 y proporción respecto a LG1.

A la vista de estos resultados las experiencias se centraron en LG1. En la Tabla 8.10 se exponen los tiempos medios de ejecución (en segundos) de cada una de las actividades desarrolladas en LG1 durante los 6 experimentos (cada experimento se realizó 10 veces), información que es presentada de forma gráfica en la Figura 8.13 y en la Figura 8.37.

Experimento	1	2	3	4	5	6
Evaluación	34,63	124,08	128,29	130,27	128,75	136,09
Cruce	5,90	6,61	6,67	6,63	6,22	6,56
Mutación	2,41	2,85	2,77	2,91	2,89	2,83
Selección	1,95	2,27	2,46	2,49	2,47	2,30
Elitismo	----	----	23,63	17,61	20,12	30,07
Intensificación	----	----	----	39,37	48,35	43,70
<b>Total</b>	<b>44,89</b>	<b>135,81</b>	<b>163,82</b>	<b>199,27</b>	<b>208,81</b>	<b>221,56</b>

Tabla 8.10: Tiempos de ejecución de las distintas actividades de LG1.

Es destacable que en todos los casos la evaluación de los individuos de la población ocupa la mayor parte del tiempo de ejecución, yendo desde aproximadamente un 60% a un 90% del total según el experimento. La introducción en el experimento 2, del cálculo del potencial geométrico del árbol de cortes en la función evaluadora, supone que el tiempo empleado por la evaluación aumente un 358%. Evidentemente, el cálculo del potencial geométrico del árbol de cortes es la tarea del algoritmo que más recursos consume. La precisión de cálculo empleada es un factor que afectará mucho a la duración de la evaluación.




Figura 8.13: Tiempos de ejecución de las distintas actividades de LG1.




Figura 8.14: Porcentaje de tiempos de ejecución de las distintas actividades de LG1.

En el experimento 3 se introduce el mantenimiento del grupo de 4 individuos élite, así como la intensificación local de la búsqueda sobre dichos individuos cuando uno de ellos es admitido en el grupo. El mantenimiento de la élite supone entre un 8,84 y un 14,42% del tiempo de cálculo. Los tiempos empleados por esta actividad varían considerablemente entre un experimento y otro, diferencias que provocan que en algunos experimentos prácticamente se doble el tiempo respecto de otros. Es sólo cuando se localiza un nuevo individuo mejor que los anteriores, cuando sus alrededores son sometidos a búsqueda local y dicho individuo es incluido en la élite, es decir, sólo cuando aparece un nuevo individuo óptimo se consume tiempo. El número de nuevos individuos óptimos que aparecen durante las 500 ejecuciones puede variar mucho de ejecución a ejecución, lo que justifica la dispersión de los valores.

La intensificación, introducida en el experimento 4, es la segunda actividad en consumo de tiempo tras la evaluación. Se activó en dos ocasiones (cada 250 generaciones) y supuso alrededor de un 20% del tiempo total de cálculo. Si se mantuviera la frecuencia de actuación y se aumentara el número de generaciones, este porcentaje podría aumentar considerablemente. Los experimentos posteriores demostraron que el uso de la intensificación local de la búsqueda supone una mejora significativa en los resultados obtenidos, sin embargo, la gran cantidad de recursos consumidos hace recomendable limitar su empleo en lo posible.

La introducción de la mutación geométrica y el cruce definido en el presente trabajo en el experimento 5 no supuso un incremento de tiempo de cálculo mensurable. El incremento de tiempo de cálculo que se muestra en el experimento 5 es debido a un aumento del tiempo dedicado a la intensificación de la búsqueda, no a la aplicación de los operadores genéticos. Así pues, la introducción de los operadores genéticos definidos en esta tesis no supone un incremento de tiempo significativo, incluso aunque se requiera de la medición del grado de convergencia de la población.

Por último, el experimento 6 introduce el ratio de planta variable, lo que se traduce en un incremento acusado del tiempo dedicado a la evaluación y al mantenimiento de la élite. El primer incremento es debido a que el cálculo del potencial geométrico del árbol de cortes es ahora algo más complejo puesto que debe calcularse para todo el intervalo de ratios de planta permitidos. El segundo incremento es debido a que cuando el ratio de planta es variable, el número de nuevos mejores individuos que deben entrar en el grupo élite aumenta, es decir, se localizan nuevos individuos óptimos con más frecuencia, aumentando el tiempo de cómputo.

Ya se ha indicado que los tiempos de cálculo pueden variar mucho según las condiciones de ejecución; con este experimento se ha tratado de conocer el efecto que, sobre dicho tiempo, puede tener el emplear o no una determinada característica del algoritmo. No obstante, y por ofrecer un orden de magnitud, en experimentos descritos posteriormente, la resolución del problema de Armour y Buffa hasta obtener resultados altamente satisfactorios, con todas las funcionalidades del algoritmo activas, en un equipo dotado con un procesador de 1,6 GHz y 2Gb de memoria RAM, requirió tiempos de cálculo en un intervalo entre 3 y 12 minutos. La gran variabilidad de los tiempos depende del grado de restricción geométrica impuesto a las actividades que forman la distribución.

## **8.4. Resolución de problemas de la bibliografía**

### **8.4.1 Introducción**

Para demostrar de manera efectiva las ventajas del método propuesto en esta tesis para localizar distribuciones en planta que respeten los requerimientos geométricos de las actividades y, simultáneamente, resulten óptimas bajo el punto de vista del resto de los criterios empleados para evaluarlas, se ha seleccionado un grupo de problemas muy conocidos en la literatura por ser empleados habitualmente para realizar comparaciones entre algoritmos. La naturaleza del problema a resolver (modelo continuo, de área desigual y con restricciones geométricas definidas) limita mucho el número de casos adecuados disponibles en la bibliografía. En muchas ocasiones, los problemas tipo son monoárea, o discretos, o no definen restricciones geométricas, o emplean dominios no rectangulares. Los problemas adecuados para este caso serán aquellos con dominios de ubicación rectangulares, áreas y formas de las actividades definidas, desiguales y restringidas.

Se han seleccionado tres problemas de diferentes niveles de complejidad para el estudio. El problema más conveniente al caso, y el más empleado en la bibliografía es el de Armour y Buffa [Armour et al., 63] de 20 actividades, empleado ya en los apartados anteriores. Éste se puede considerar un problema de tamaño medio. Se resolverá también el problema conocido como de Francis y White descrito en [Francis et al., 74]; éste es de menor tamaño que el anterior constando únicamente de 12 actividades. Por último, se ha escogido un caso de mayor complejidad, que se presenta en la bibliografía como muy complejo debido a las grandes restricciones geométricas y al número de actividades a distribuir. Se trata del problema de 30 actividades expuesto en [Tam et al., 91].

### **8.4.2 Descripción de los problemas a resolver**

#### **8.4.2.1 El problema de Francis y White**

Este problema se describe en "Facility Layout and Location" [Francis et al., 74] como un ejemplo de la aplicación del algoritmo CRAFT. Es, por tanto, un problema planteado para su resolución mediante un modelo discreto del dominio de ubicación, aunque ha sido resuelto mediante modelos continuos del espacio en [Santamarina, 95]. El dominio de ubicación original está dividido en una rejilla cuadrangular de 16x16 celdas de 4x4 pies cada una, en el que existe una zona determinada que no puede ser empleada para ubicar actividades.

Se plantea la distribución de 12 actividades con flujo de materiales entre ellas en dicho dominio de forma tal que se minimice el coste del transporte. El área restringida del dominio es tratada como una actividad sin flujo con las restantes, por lo que el problema se plantea como de 13 actividades. No se especifica ningún tipo de restricción de la forma de las actividades y la métrica empleada para la medición de distancia entre las actividades es la Manhattan. Las distancias se miden desde los centroides de las actividades. Las dimensiones de las diferentes actividades se recogen en la Tabla 8.11.

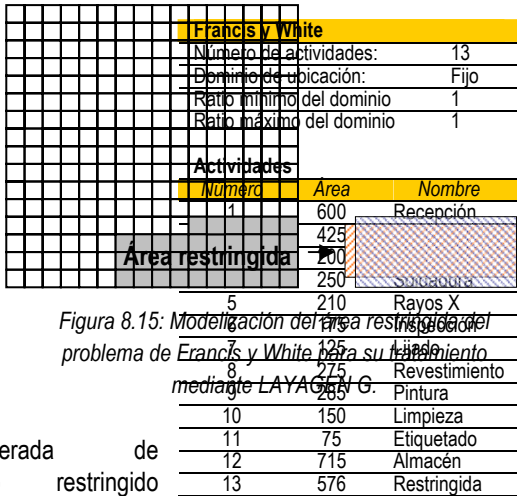


Figura 8.15: Modelación del área restringida del problema de Francis y White para su planteamiento mediante LAYA G.

Tabla 8.11: Datos del problema de Francis y White.

El área restringida cuya forma es fija según el problema original, se tratará como una actividad sin flujo (actividad 13) cuya área es igual a la indicada en dicho problema, y cuyo ratio de aspecto debe estar en el intervalo  $[0,3, 0,4]$  siendo orientación libre. Así, dicho adoptará una forma similar a la

considerada de recinto restringido solicitada (Figura 8.15).

En el problema original se ofrece una matriz de flujos entre actividades y una matriz de costes de transportes entre actividades en milésimos de dólar por cada 0,25 pies recorridos. Ambas matrices son asimétricas (ver [Francis et al., 74]). Para la resolución del problema se elabora una matriz cuyos elementos son el producto de los elementos de la matriz de flujos por los de la matriz de costes. Además cada elemento se multiplica por 4 dadas las unidades de la matriz de costes entre cada actividad. El resultado es que la matriz cuyos elementos habrá que multiplicar por las distancias entre las actividades, y que representa en definitiva lo que se trata de minimizar, es la ofrecida en la Tabla 8.12.

	A1	A2	A3	A4	A5	A6	A7	A8	A9	A10	A11	A12	A13
A1	*	750	112,5										
A2		*	307,5	49									
A3		49	*	123		165							
A4				*	315								
A5					*	90	150						
A6						*	150	50		120			
A7						100	*			50		360	
A8							50	*					
A9									*		65	210	
A10									255	*			
A11											*	100	
A12												*	
A13													*

Tabla 8.12: Flujos por coste del transporte de materiales entre actividades en el problema de Francis y White.

### 8.4.2.2 El problema de Armour y Buffa

El problema de Armour y Buffa ya ha sido descrito de manera somera en el apartado 8.2 del presente capítulo. En la Tabla 8.3 se muestran los datos de las 20 actividades y en la Tabla 8.4 los flujos de materiales entre ellas. Se emplea como métrica de la distancia la rectilínea. Aunque en la versión original del problema no se restringe de manera explícita la forma de las actividades, en estudios posteriores en los que se resuelve dicho problema sí que se imponen restricciones geométricas [Tong, 91; Tate et al., 95; Kim et al., 98; Gau et al.,

99; Ozdemir et al., 03; González-García, 05]. Este hecho, junto con el de tratarse del problema más empleado en modelos continuos de resolución lo convierten en un test ideal para medir la eficacia de LAYAGEN G frente a otros algoritmos.

#### 8.4.2.3 El problema de Tam de 30 actividades

Se trata del problema que Kar Yam Tam plantea en “*A hierarchical approach to the facility layout problem*” [Tam et al., 91]. La selección de este problema para esta fase experimental del trabajo obedece a que éste fue generado por Tam como modelo de problema complejo y fuertemente restringido geoméricamente. Consta de 30 actividades de tamaños muy diversos, y cuyas restricciones geométricas son muy estrictas en unos casos y lo son menos en otros. El citado artículo presenta un método de resolución del problema de distribución en planta que respeta las restricciones geométricas, basado en una estrategia *divide y vencerás*. El método divide el problema en varios grupos de actividades mediante técnicas de *clustering* generando un layout independiente para cada grupo de actividades. Posteriormente se genera un layout global considerando cada cluster como una gran actividad.

La pérdida de eficacia que supone la división del problema en subproblemas y la generación de layouts independientes para cada uno de ellos, es considerada por Tam como un mal menor que, en contrapartida, permite afrontar problemas de tamaño grande y con fuertes restricciones geométricas. Las soluciones obtenidas mediante este sistema son, además, poco compactas, con numerosas áreas muertas entre las actividades (ver Figura 8.16). Tam indica en dicho artículo que la existencia de estas áreas es inevitable para la resolución de problemas tan complejos como el planteado. Como se demostrará en el presente capítulo, LAYAGEN G es capaz de obtener soluciones a problemas geoméricamente complejos como el de Tam, siendo dichas soluciones de menor coste y más compactas.




Figura 8.16: Solución a un problema de 8 actividades mediante el método jerárquico de Tam. Adaptado de [Tam et al., 91].

El problema planteado por Tam posee actividades cuyas áreas van de 3 a 36 unidades, con una media de 11,93 y una desviación típica de 8,55 (ver Tabla 8.13). La flexibilidad de los ratios de aspecto también es muy variable, yendo desde 1,25 hasta 0 y considerándose todas de orientación libre. Existen 4 actividades sin flexibilidad geométrica a las que se les exige que sean cuadrados perfectos (las actividades 17, 18, 27 y 28). En la adaptación del problema para su resolución mediante LAYAGEN G, a dichas actividades se les ha dotado de una mínima flexibilidad, permitiendo que sus ratios de aspecto oscilen en el intervalo  $[0,95, 1]$ . El valor del flujo de materiales entre actividades se expone en la Tabla 8.14.

Dadas las características descritas del problema se ha considerado muy adecuada la inclusión de éste en la fase experimental, a pesar de que no se ha localizado otras referencias bibliográficas en la que se emplee como test. Esto es quizá debido precisamente a la dificultad intrínseca del problema y a que la solución óptima que aporta Tam es difícilmente comparable con otras posibles soluciones.

Tam30				
Número de actividades:	30			
Dominio de ubicación:	Variable			
Ratio mínimo del dominio	---			
Ratio máximo del dominio	---			
Actividades				
Número	Área	Orientación	Ratio mínimo	Ratio máximo
1	24	Libre	0,8	1
2	16	Libre	0,75	1,15
3	36	Libre	0,6	1,85
4	8	Libre	0,3	1,1
5	21	Libre	0,9	1,18
6	17,5	Libre	0,5	1
7	3,6	Libre	0,3	1,4
8	15,4	Libre	0,6	1,25
9	20	Libre	0,9	1
10	19,5	Libre	1,2	1,8
11	16	Libre	0,85	1,1
12	9	Libre	0,9	1
13	9	Libre	0,8	1,1
14	25	Libre	0,92	1,05
15	4	Libre	0,85	1,15
16	3	Libre	0,9	1
17	4	Libre	1 (0,95)	1
18	9	Libre	1 (0,95)	1
19	4,5	Libre	0,7	1,1
20	5	Libre	0,5	1,5
21	16	Libre	0,85	1,1
22	9	Libre	0,9	1
23	9	Libre	0,8	1,1
24	25	Libre	0,92	1,05
25	4	Libre	0,85	1,15
26	3	Libre	0,9	1
27	4	Libre	1 (0,95)	1
28	9	Libre	1 (0,95)	1
29	4,5	Libre	0,7	1,1
30	5	Libre	0,5	1,5

Tabla 8.13: Datos de las actividades del problema de Tam de 30 actividades.

	A 1	A 2	A 3	A 4	A 5	A 6	A 7	A 8	A 9	A 10	A 11	A 12	A 13	A 14	A 15	A 16	A 17	A 18	A 19	A 20	A 21	A 22	A 23	A 24	A 25	A 26	A 27	A 28	A 29	A 30
A 1	*	3	2	0	0	2	10	5	0	5	2	5	0	0	2	0	5	6	3	0	1	10	0	10	2	1	1	1	0	1
A 2	3	*	4	0	10	4	0	0	2	2	1	0	5	0	0	0	0	2	0	1	6	1	0	1	2	2	5	1	10	5
A 3	2	4	*	3	4	0	5	5	5	1	4	1	0	4	0	4	0	6	3	2	5	5	2	1	0	0	3	1	0	2



A 4	0	0	3	*	0	0	0	2	2	0	6	0	2	5	2	5	1	1	1	1	2	2	4	0	2	0	2	2	5	5
A 5	0	10	4	0	*	5	2	0	0	0	0	2	0	0	0	2	1	0	0	2	0	5	1	0	2	1	0	2	1	
A 6	2	4	0	0	5	*	1	2	2	1	4	10	10	2	5	5	0	5	0	0	0	10	0	0	0	4	0	10	1	1
A 7	10	0	5	0	2	1	*	10	10	5	10	10	6	0	0	10	2	1	10	1	5	5	2	3	5	0	2	0	1	3
A 8	5	0	5	2	0	2	10	*	1	3	5	0	0	0	2	4	5	2	10	6	0	5	5	2	5	0	5	5	0	2
A 9	0	2	5	2	0	2	10	1	*	10	2	1	5	2	0	3	0	2	0	0	4	0	5	2	0	5	2	2	5	2
A 10	5	2	1	0	0	1	5	3	10	*	5	5	6	0	1	5	5	0	5	2	3	5	0	5	2	10	10	1	5	2
A 11	2	1	4	6	0	4	10	5	2	5	*	0	0	1	2	1	0	2	0	0	0	6	6	0	4	5	3	2	2	10
A 12	5	0	1	0	2	10	10	0	1	5	0	*	5	5	2	0	0	0	0	2	0	4	5	10	1	0	0	0	0	1
A 13	0	5	0	2	0	10	6	0	5	6	0	5	*	2	0	4	2	2	1	0	6	2	1	5	5	0	0	1	5	5
A 14	0	0	4	5	0	2	0	0	2	0	1	5	2	*	2	1	0	5	3	10	0	0	4	2	0	0	4	2	5	5
A 15	2	0	0	2	0	5	0	2	0	1	2	2	0	2	*	4	5	1	0	1	0	5	0	2	0	0	5	1	1	0
A 16	0	0	4	5	0	5	10	4	3	5	1	0	4	1	4	*	0	3	0	2	2	0	2	0	5	0	5	2	5	10
A 17	5	0	0	1	2	0	2	5	0	5	0	0	2	0	5	0	*	2	2	0	0	0	6	5	3	5	0	0	5	1
A 18	6	2	6	1	1	5	1	2	2	0	2	0	2	5	1	3	2	*	5	1	2	10	10	4	0	0	5	0	0	0
A 19	3	0	3	1	0	0	10	10	0	5	0	0	1	3	0	0	2	5	*	0	5	5	1	0	5	2	1	2	10	10
A 20	0	1	2	1	0	0	1	6	0	2	0	2	0	10	1	2	0	1	0	*	5	2	1	3	1	5	6	5	5	3
A 21	1	6	5	2	2	0	5	0	4	3	0	0	6	0	0	2	0	2	5	5	*	4	0	1	0	0	0	5	0	0
A 22	10	1	5	2	0	10	5	5	0	5	6	4	2	0	5	0	0	10	5	2	4	*	5	0	4	4	5	0	2	5
A 23	0	0	2	4	5	0	2	5	5	0	6	5	1	4	0	2	6	10	1	1	0	5	*	0	4	4	1	0	2	2
A 24	10	1	1	0	1	0	3	2	2	5	0	10	5	2	2	0	5	4	0	3	1	0	0	*	5	5	0	1	0	0
A 25	2	2	0	2	0	0	5	5	0	2	4	1	5	0	0	5	3	0	5	1	0	4	4	5	*	1	0	10	1	0
A 26	1	2	0	0	2	4	0	0	5	10	5	0	0	0	0	0	5	0	2	5	0	4	4	5	1	*	0	0	0	0
A 27	1	5	3	2	1	0	2	5	2	10	3	0	0	4	5	5	0	5	1	6	0	5	1	0	0	0	*	0	0	10
A 28	1	1	1	2	0	10	0	5	2	1	2	0	1	2	1	2	0	0	2	5	5	0	0	1	10	0	0	*	2	2
A 29	0	10	0	5	2	1	1	0	5	5	2	0	5	5	1	5	5	0	10	5	0	2	2	0	1	0	0	2	*	2
A 30	1	5	2	5	1	1	3	2	2	2	10	1	5	5	0	10	1	0	10	3	0	5	2	0	0	0	10	2	2	*

Tabla 8.14: Flujo de materiales entre las actividades del problema de Tam de 30 actividades.

### 8.4.3 Medición de la complejidad de los problemas

En la bibliografía se han propuesto diversas formas de medir la complejidad de un problema de distribución en planta, siendo las más extendidas las basadas en el concepto de *dominancia de flujo* ( $f$ ) de la matriz de flujos [Vollmann et al., 66], calculada como 100 por el cociente de la desviación estándar de los valores de la matriz de flujos del problema y la media de dichos valores:

$$f = 100 \frac{s}{m}; \quad m = \frac{\left( \sum_{i=1}^n \sum_{j=1}^n w_{ij} \right)}{n^2}; \quad s = \left[ \frac{\left( \sum_{i=1}^n \sum_{j=1}^n (w_{ij} - m)^2 \right)}{n^2 - 1} \right]^{\frac{1}{2}}$$

ecuaciones en las que  $w_{ij}$  es el flujo de materiales entre la actividad  $i$  y  $j$  expresada en la matriz de flujos y  $n$  es el número de actividades implicadas en el problema. Según [Vollmann et al., 66; Block, 77], una dominancia de flujo superior a 200% indica que existen flujos obvios entre las actividades y que, en general, dicho problema puede ser resuelto por métodos visuales sin necesidad de algoritmos.

En [Block, 79] se introduce el *porcentaje de complejidad* ( $C_f$ ) de un problema, como una función de la dominancia de flujo y del número de actividades del mismo. Para ello se calculan los valores máximos y mínimos que puede adoptar la dominancia para un número dado de actividades ( $f_{ub}$  y  $f_{lb}$ ); estos valores servirán como principio y final de una escala de complejidad que comprenderá desde 0% (cuando  $f = f_{lb}$ ) a 100% (cuando  $f = f_{ub}$ ). El porcentaje de complejidad se calcula como:

$$C_f = 100 \frac{f_{ub} - f}{f_{ub} - f_{lb}};$$

Puede representarse en una gráfica el porcentaje de complejidad frente al número de actividades del problema para cada uno de las dominancias de flujo, obteniendo curvas como las mostradas en la Figura 8.17.




Figura 8.17: Complejidad del problema frente a número de actividades y dominancia de flujo (adaptado de [Block, 79]).

A pesar de ser una medida de la complejidad de un problema muy extendida en la bibliografía, su empleo es muy criticado en [Herroelen et al., 85], fundamentalmente debido a los siguientes motivos:

- las matrices de flujo entre actividades son simétricas en unos problemas mientras que


en otro son asimétricas. Aparentemente, los elementos de una matriz de flujo simétrica representan la suma de los flujos entre actividades en ambas direcciones, mientras que los de una asimétrica representan flujos unidireccionales, sin embargo no existe acuerdo al respecto. Dado que las fórmulas antes expuestas recorren toda la matriz de flujos, el uso de una matriz asimétrica implicará de manera incorrecta que es más difícil el diseño de un layout con flujos asimétricos entre las actividades. Sería necesario, pues, un acuerdo respecto al modo de representar los flujos mediante la matriz de flujos.

- los términos de la diagonal de la matriz entran en los cálculos adoptando el valor 0, cuando estos no deberían ser considerados pues no representan flujo alguno entre actividades.
- en general, más que los flujos de materiales entre actividades se debe minimizar el coste de dicho transporte, por lo que el cálculo de la complejidad debe realizarse sobre una matriz de flujos en la que cada término se ha multiplicado por el coste del desplazamiento por unidad de distancia.

Herroelen y Van Gils encuentran problemas también en el cálculo de los valores de flujo máximo y mínimo ( $f_{ub}$  y  $f_{lb}$ ). Además, cabría añadir que, para el problema de la distribución de actividades de área desigual, la complejidad dependerá en gran medida de los aspectos geométricos del problema (áreas y rigidez de las restricciones formales).

Existen otras variantes del cálculo de la dominancia de flujo que tratan de resolver estos inconvenientes. Por ejemplo, en [Mojena et al., 76] el cálculo se realiza siempre sobre el triángulo inferior de una matriz simétrica, dejando fuera del cálculo la diagonal. No obstante, el sistema de cálculo de Block ha sido ampliamente empleado, y en el presente trabajo se usará, más para comparar las dificultades relativas de la resolución de cada uno de los problemas planteados, que como medida absoluta de dicha dificultad. Los problemas de Armour y Buffa y de Tam poseen matrices de flujo simétricas. Sin embargo, la matriz de flujos del problema de Francis y White es asimétrica, por lo que el cálculo de la dominancia de flujo se verá desvirtuado. Para solventar este problema, la matriz sobre la que se calculará la dominancia de flujo en el problema de Francis y White no será la mostrada en la Tabla 8.12, sino la matriz resultante de sumar a ésta su transpuesta, de forma que se obtiene una matriz simétrica en la que cada elemento representa el coste del flujo bidireccional entre actividades.

Tras realizar los cálculos correspondientes, las dominancias de flujo de los problemas planteados son: 264,7 para el de Francis y White, 253,6 para el de Armour y Buffa y 111 para el de Tam. A partir de estos valores se han elaborado las curvas de complejidad mostradas en la Figura 8.18, resultando que el porcentaje de complejidad de los problemas es: 29,4% para el de Francis y White (considerado como de 13 actividades), 45,8% para el de Armour y Buffa y 82,5% para el de Tam.



A partir de estos valores se deduce que el problema de Francis y White es el más simple de los tres planteados, y que el de Tam es significativamente más complejo que los dos restantes. Esto sería más así si en el cálculo de la complejidad se incluyera el grado de diversidad geométrica y la rigidez de las restricciones impuestas a las actividades.

#### **8.4.4 Resultados de los problemas escogidos y comparación con soluciones alcanzadas mediante otros métodos**

##### **8.4.4.1 El problema de Francis y White**

En [Francis et al., 74] no se restringe de ninguna manera la forma que pueden adoptar las áreas asignadas a las actividades. Únicamente se ofrecen datos sobre las áreas de las actividades y del dominio de ubicación, la forma de la planta (cuadrada), la existencia de una zona restringida y los flujos y costes del transporte de materiales entre actividades. Dado que no existen datos sobre las restricciones geométricas, se realizaron experimentos con diferentes ratios alto-ancho permitidos de las actividades cada vez más estrictos. Como ya se indicó en 8.4.2.1 la zona restringida fue modelizada como una actividad cuyo ratio alto-ancho debía permanecer en el intervalo  $[0,3, 0,4]$  con orientación libre. Dicha actividad debía situarse en una de las esquinas de la planta (tal y como se plantea en el problema original), por lo que se introdujo en la función evaluadora de LG2 una penalización si la distribución evaluada no cumplía dicho requisito. Los parámetros empleados fueron los mismos en todas las ejecuciones y se muestran en la Tabla 8.15.

En cada experimento se ejecutó una única vez LG1, obteniendo un árbol de cortes sobre el que se ejecutó 10 veces LG2, recogiendo como resultado la mejor distribución encontrada. El proceso fue llevado a cabo de manera automática por el software desarrollado, y empleó como máximo 249 segundos en un equipo con procesador de 1GHz y 1Gb de memoria R.A.M.

LG1			LG2		
Acrónimo	Nombre del parámetro	FW	Acrónimo	Nombre del parámetro	FW
n	Tamaño de la población	30	n	Tamaño de la población	30
Pc	Probabilidad de cruce	0,95	Pc	Probabilidad de cruce	0,90
Pm	Probabilidad de mutación	0,80	Pm	Probabilidad de mutación	0,60
Ng	Número de generaciones	1000	Ng	Número de generaciones	1000
Cr	Coefficiente relacional	90000	Cr	Coefficiente relacional	1
Cg	Coefficiente geométrico	100000	Cg	Coefficiente geométrico	100000
Eg	Exponente geométrico	1		Métrica (Manhattan/euclídea)	Manhattan
Pg	Precisión geométrica	4		Estrategia elitista	activa
	Mutación geométrica	activa	le <sub>2</sub>	Intensidad de elitismo	4
Pmg	Prob. de mutación geométrica	0,92		Exploración de ratios	----
	Intensificación de búsqueda	activa		Ratio recomendado en Fase 1	----
Fib	Frecuencia de intensificación	300	Na	Número de ejec. por árbol	10
lib	Intensidad de intensificación	4	p	Exp. función penalizadora	5
	Aleatoriedad de intensificación	inactiva			
	Estrategia elitista	activa			
le <sub>1</sub>	Intensidad de elitismo	4			
	Intensificación en la élite	activa			

Tabla 8.15: Parámetros de ejecución para el problema de Francis y White.

En el primer experimento se fijó el ratio alto-ancho mínimo de las actividades en 0,3 (a excepción de la zona restringida), obteniendo como mejor distribución la representada en la Figura 8.19, con un coste asociado al flujo de materiales de 72411,33.




Figura 8.19: Solución al problema de Francis y White obtenida mediante LAYAGEN G con ratio mínimo de las actividades 0,3.

En el segundo experimento se fijó el ratio alto-ancho mínimo de las actividades en 0,4. La mejor distribución obtenida es la representada en la Figura 8.20, con un coste asociado al flujo de materiales de 78779,08. Este coste es 6367,75 unidades superior al obtenido en el experimento anterior debido a la mayor restricción geométrica.

En el tercer experimento se fijó el ratio alto-ancho mínimo de las actividades en 0,5. Obteniendo, como mejor distribución la representada en la Figura 8.21, con un coste asociado al flujo de materiales de 79397,59, ligeramente superior al de la distribución anterior.

Además de estas tres experiencias se realizaron algunos ensayos modificando las condiciones del problema.

En el primero de ellos se fijó el ratio mínimo de las actividades en 0,5 y se eliminó la penalización introducida para imponer que la zona restringida permaneciera en una esquina de la planta. La mejor distribución obtenida en estas condiciones fue la representada en la Figura 8.22 a), cuyo coste fue 76256,22, sensiblemente inferior al obtenido con la penalización. Como puede observarse la zona restringida no permanece en este caso en una esquina de la planta.

En el segundo ensayo se fijó el ratio mínimo de las actividades en 0,4. Se mantuvo la penalización introducida para imponer que la zona restringida

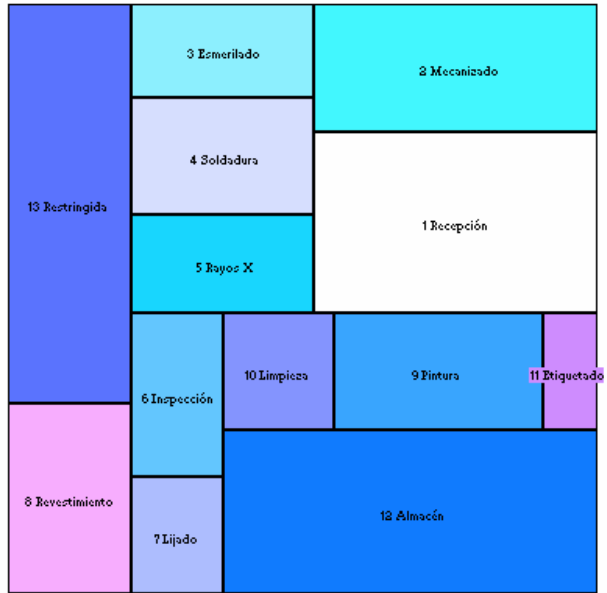


Figura 8.20: Solución al problema de Francis y White obtenida mediante LAYAGEN G con ratio mínimo de las actividades 0,4.

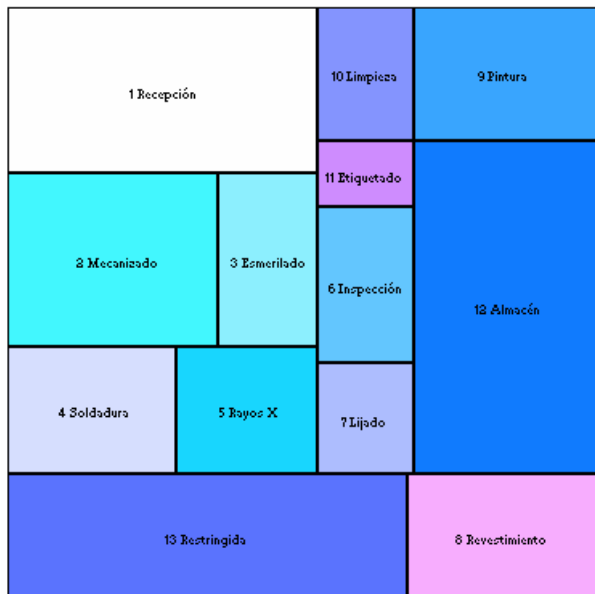


Figura 8.21: Solución al problema de Francis y White obtenida mediante LAYAGEN G con ratio mínimo de las actividades 0,5.

permaneciera en una esquina de la planta, pero se eliminó la condición de que su ratio tuviera que permanecer en el intervalo  $[0,3, 0,4]$ . La mejor distribución obtenida en estas condiciones fue la representada en la Figura 8.22 b), cuyo coste fue 75175,2. El color rojo de la actividad 13 indica que incumple la restricción formal original del problema.

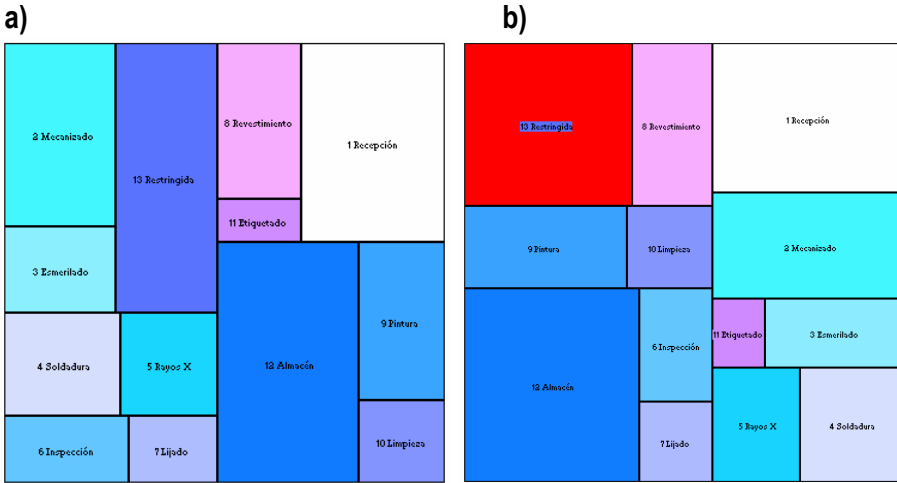


Figura 8.22: Diversas soluciones al problema de Francis y White.

Como ya se ha indicado, este problema fue generado para su resolución mediante técnicas que modelizaran el espacio de la planta de manera discreta. La solución propuesta en [Francis et al., 74], obtenida mediante CRAFT se muestra en la Figura 8.23; el coste del flujo de materiales correspondiente es 87963.

En la Figura 8.24 se muestra la solución propuesta en [Contero-González, 95] obtenida mediante técnicas de recocido simulado; el coste del flujo de materiales correspondiente es 77546.

En [Santamarina, 95] se resuelve el problema mediante técnicas de corte empleando un modelo continuo del espacio de la planta. El coste asociado al transporte de materiales de dicha distribución es 78796. Como puede observarse el ratio de la planta no es 1. Esto es debido a que Santamarina plantea el problema como si el ratio de la planta no fuera fijo, permitiendo que el algoritmo localice el ratio óptimo. Asimismo no se contempla las restricciones de

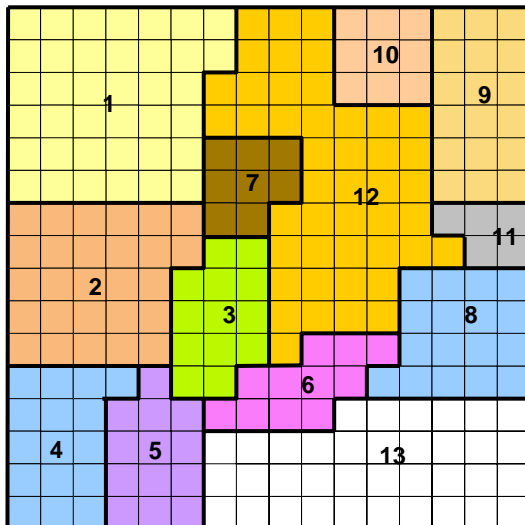


Figura 8.23: Solución al problema de Francis y White propuesta en [Francis et al., 74].

posición y forma de la actividad 13.

A la vista de los resultados, puede concluirse que LAYAGEN G supera las soluciones ofrecidas en la bibliografía. Sólo la solución de Contero posee un coste similar a los obtenidos mediante dicho algoritmo, siendo a costa de una calidad formal sensiblemente inferior inherente a los métodos que emplean modelos discretos del espacio de la planta. Como ya se discutió, estos procedimientos generan departamentos con formas complejas que difícilmente podrán ser aprovechados plenamente.




Figura 8.24: Solución al problema de Francis y White propuesta en [Contero-González, 95].

La solución de Santamarina es geoméricamente más compacta, no obstante las restricciones geométricas no son muy estrictas y algunas actividades son excesivamente esbeltas. Por otra parte esta autora planteó el problema de forma distinta al original.




Figura 8.25: Solución al problema de Francis y White propuesta en [Santamarina, 95].

Esta experiencia ha permitido, además, comprobar el gran control sobre la geometría que proporciona LAYAGEN G al planificador, pudiendo éste actuar sobre las restricciones de las actividades o los pesos asignados a cada criterio, obteniendo siempre soluciones de bajo coste.

#### 8.4.4.2 El problema de Armour y Buffa

Entre los muchos trabajos en los que se aborda la resolución de este problema, el más completo es el de Tate y Smith de 1995 [Tate et al., 95]. En este artículo se ofrecen



soluciones al problema para distintos ratios de aspecto ancho-alto permitidos (1000, 50, 25, 15, 10, 7, 5, 4, 3, 2 y 1,75), iguales para todas las actividades y considerando éstas de orientación libre. Los costes del transporte de la mejor solución de cada caso se muestran en la Tabla 8.16. Como es lógico los costes crecen conforme las restricciones geométricas se hacen más estrictas.

Ratio máximo permitido de las actividades	Coste de la mejor distribución obtenida
1000	1638,5
50	3009,5
25	3635,9
15	4296,1
10	4633,3
7	5255,0
5	5524,7
4	5743,1
3	5832,6
2	6171,1
1,75	7205,4

Tabla 8.16: Coste de las soluciones del problema de Armour y Buffa en [Tate et al., 95].

En realidad, las soluciones halladas para los ratios superiores a 5 disponen las actividades en departamentos excesivamente alargados, siendo improbable que puedan albergar ningún tipo de actividad productiva. En la Figura 8.26 (a) y (b) se muestran las soluciones correspondientes a los ratios máximos permitidos de las actividades 5 y 3 respectivamente. Como puede observarse la calidad geométrica de dichas soluciones es elevada (si se entiende por calidad el aproximarse a la forma cuadrada). Además, los autores trataron de localizar una distribución en la que las actividades fueran lo más cuadradas posible. La mejor de dichas distribuciones tuvo como mínimo ratio de aspecto para todas las actividades 1,70667, y un coste de 6662,9 (Figura 8.26 c).

A partir de estos resultados se va demostrar la eficacia del potencial geométrico del árbol de cortes como indicador de la capacidad de un árbol dado para generar distribuciones que cumplan los requerimientos geométricos impuestos en el problema. Aunque en el estudio de estos autores se emplearon *flexible bay structures* [Tong, 91] para la resolución del problema, es posible obtener múltiples árboles de corte capaces de generar la distribución de la Figura 8.26 (c). En la Figura 8.27 se presenta uno de esos árboles, y en la Figura 8.30 la representación de su potencial geométrico en función del ratio de la planta. Como puede observarse el valor del potencial es nulo para los intervalos  $[0,56, 0,59]$  y su simétrico respecto de  $\pi/4$ . Dicho intervalo indica que es posible encontrar distribuciones que cumplan las restricciones geométricas del problema para plantas cuyo ratio medido mediante ángulos (el que forma la diagonal del rectángulo con la horizontal en radianes) pertenezca al intervalo  $[0,627, 0,669]$  o al intervalo  $[1,495, 1,595]$ , siendo imposible para los demás ratios. El ratio de la planta del problema pertenece, efectivamente, al primero de los intervalos.

Se puede comprobar que imponiendo como ratio de aspecto mínimo para todas las actividades el valor 1,70660, que es ligeramente más restrictivo que el de Tate y Smith, se obtiene un potencial geométrico no nulo para cualquier ratio de planta. Esto resulta lógico si

se observa que en la solución dada por Tate y Smith Figura 8.26 (c), el ratio de aspecto de las actividades P y K es sólo ligeramente inferior al valor máximo permitido. Por otra parte esto indica que no es posible encontrar, a partir de dicho árbol de cortes, soluciones geoméricamente aceptables si las restricciones de forma se hacen levemente más restrictivas que las planteadas por estos autores.

Así pues, el potencial geométrico de un árbol de cortes permite conocer a priori, la calidad geométrica máxima que se puede esperar de las distribuciones que se obtendrán de dicho árbol.

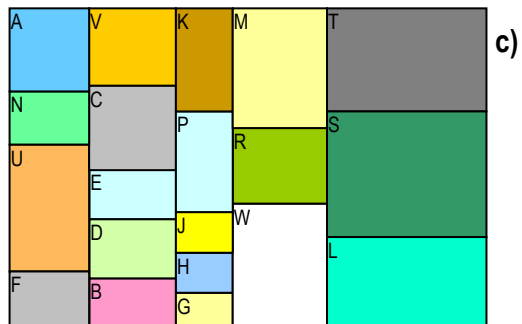
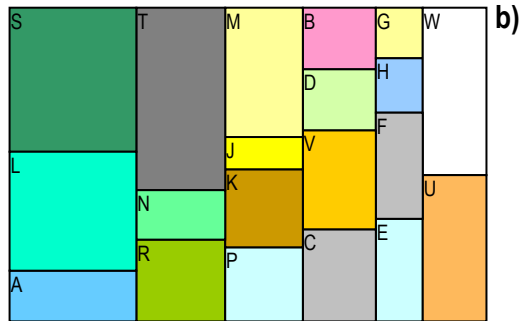



Figura 8.26: Soluciones del problema de Armour y Buffa en [Tate et al., 95].




Figura 8.27: Árbol de cortes capaz de generar la distribución propuesta en [Tate et al., 95] como solución al problema de Armour y Buffa.

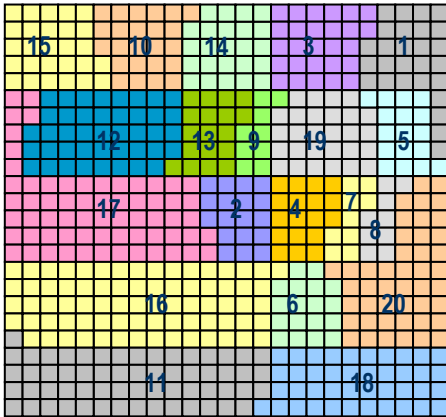


Figura 8.28: Solución al problema de Armour & Buffa [Armour et al., 63] propuesta en [Wang et al., 05].




Figura 8.29: Solución del problema de Armour y Buffa en [Kim et al., 98].

Retomando el tema de las soluciones al problema de Armour y Buffa localizadas en la bibliografía, en [Kim et al., 98] se resuelve el problema mediante un procedimiento que emplea matrices de localización y un modelo continuo del espacio de la planta. Kim y Kim proporcionan el mejor resultado del problema desde el punto de vista geométrico que ha sido posible localizar en la bibliografía. La distribución es la mostrada en la Figura 8.29. El ratio máximo permitido para las actividades es 1,4 y el coste del transporte de materiales es 6824,66. Estos valores son muy inferiores a los de la mejor distribución de Tate y Smith.




Figura 8.30: Potencial geométrico del árbol de cortes capaz de generar la distribución propuesta en [Tate et al., 95] como solución al problema de Armour y Buffa.

Otras soluciones al problema se localizan en [Armour et al., 63] con coste 7862, [Contero-González, 95] con coste 6886, o dos soluciones presentadas en [Wang et al., 05] con costes que 5926 y 6777. No obstante, estos autores resuelven el problema empleando un modelo discreto de espacio de la planta, y las formas de los departamentos resultan en general complejas. Como muestra se ofrece la solución de Wang, Hu y Ku de coste 6777 en

la Figura 8.28.

En la resolución del problema mediante LAYAGEN G se realizaron experimentos variando los ratios máximos de aspecto de las actividades. Se comenzó con un ratio de 1,7, ligeramente más restrictivo que el más restrictivo de Tate y Smith, y se fue aumentando el grado de restricción en sucesivos experimentos. Los parámetros empleados pueden consultarse en la Tabla 8.17.

LG1			LG2		
Acrónimo	Nombre del parámetro	AB	Acrónimo	Nombre del parámetro	AB
n	Tamaño de la población	30	n	Tamaño de la población	30
Pc	Probabilidad de cruce	0,95	Pc	Probabilidad de cruce	0,90
Pm	Probabilidad de mutación	0,80	Pm	Probabilidad de mutación	0,60
Ng	Número de generaciones	1500	Ng	Número de generaciones	1000
Cr	Coficiente relacional	90000	Cr	Coficiente relacional	1
Cg	Coficiente geométrico	100000	Cg	Coficiente geométrico	100000
Eg	Exponente geométrico	1		Métrica (Manhattan/euclídea)	Manhattan
Pg	Precisión geométrica	4		Estrategia elitista	activa
	Mutación geométrica	activa	le <sub>2</sub>	Intensidad de elitismo	4
Pmg	Prob. de mutación geométrica	0,92		Exploración de ratios	----
	Intensificación de búsqueda	activa		Ratio recomendado en Fase 1	----
Fib	Frecuencia de intensificación	400	Na	Número de ejec. por árbol	10
lib	Intensidad de intensificación	4	p	Exp. función penalizadora	5
	Aleatoriedad de intensificación	inactiva			
	Estrategia elitista	activa			
le <sub>1</sub>	Intensidad de elitismo	4			
	Intensificación en la élite	activa			

Tabla 8.17: Parámetros de ejecución para el problema de Francis y White.


Los resultados obtenidos en cada experimento se muestran en la Tabla 8.18. El primer experimento, con ratio 1,7 mejoró significativamente el resultado de Tate y Smith para dicho ratio (6662,9). Como es lógico, los valores del coste del transporte aumentaron conforme aumentaron las restricciones geométricas. Para ratios máximos de 1,4 el valor obtenido mejora sustancialmente el de Kim y Kim para el mismo ratio (6824,66).

Ratio máximo permitido de las actividades	Coste del transporte de materiales LAYAGEN G
1,7	6084,62
1,55	6189,85
1,4	6553,46
1,35	6632,65
1,225	8897,38

Tabla 8.18: Coste del transporte de materiales de las soluciones del problema de Armour y Buffa obtenidas mediante LAYAGEN G.


Ni el procedimiento de Kim y Kim, ni el de Tate y Smith fueron capaces de localizar soluciones para ratios máximos más estrictos. LAYAGEN G, en cambio, fue capaz de encontrar soluciones para ratios máximos de 1,35 y 1,225. Las distribuciones solución para

cada ratio se presentan en la Tabla 8.19




Ratio max: 1,7;

Coste transporte:6084,62




Ratio max: 1,55;

Coste transporte: 6189,85



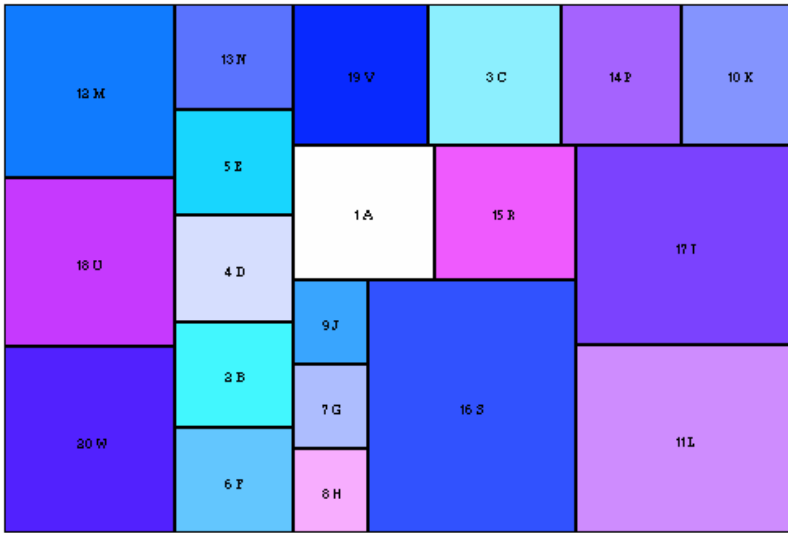
Ratio max: 1,4;

Coste transporte: 6553,46



Ratio max: 1,35;

Coste transporte: 6632,65



Ratio max: 1,225;

Coste transporte: 8897,38

Tabla 8.19: Soluciones al problema de Armour y Buffa obtenidas mediante LAYAGEN G.

La dificultad del problema crece enormemente conforme aumentan las restricciones geométricas, por lo que no fue posible localizar soluciones para ratios máximos permitidos inferiores a 1,225.

Se realizaron más experimentos sobre el mismo problema considerando ahora que el ratio de la planta no era fijo, y que podía oscilar en el intervalo  $[0,4, 1]$ , permitiendo que LAYAGEN G determinara el ratio idóneo. La intención era comprobar la posibilidad de localizar distribuciones con ratios máximos permitidos para las actividades inferiores a 1,225.

En la primera ejecución se fijó el ratio máximo de las actividades en 1,2, localizando distribuciones que cumplieran dichos requerimientos. La mejor de ellas supuso un coste de 8463,29 con un ratio de planta de 0,45. La distribución se muestra en la Figura 8.31.

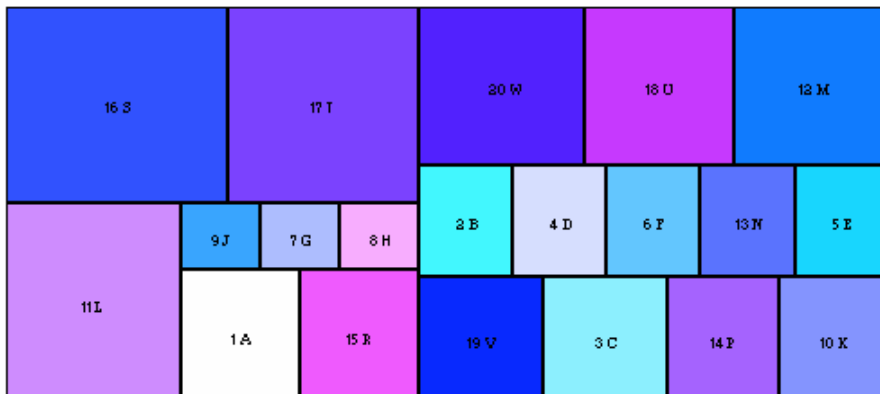



Figura 8.31: Solución al problema de Armour y Buffa con actividades de ratio inferior a 1,2 y ratio de planta 0,45.

Posteriores ejecuciones fueron disminuyendo el ratio máximo permitido para las actividades. No fue posible localizar soluciones para ratios inferiores a 1,1, siendo la restricción más estricta para la que se pudo localizar soluciones el ratio 1,12. La mejor de dichas soluciones tuvo un coste de 8646,19 y un ratio de planta de 0,435 y se muestra en la Figura 8.32.



*Figura 8.32: Solución al problema de Armour y Buffa con actividades de ratio inferior a 1,12 y ratio de planta 0,435.*

En conclusión, LAYAGEN G demostró su superioridad frente a otros algoritmos mejorando las principales soluciones al problema de Armour y Buffa de la bibliografía, no sólo en cuanto al coste del transporte de materiales sino en cuanto al control geométrico de los espacios.

#### 8.4.4.3 El problema de Tam de 30 actividades

Como se indicó en la descripción que se hizo en 8.4.2.3 se trata de un problema complejo y fuertemente restringido geométricamente. Se tratará en este apartado de probar que LAYAGEN G es capaz de resolver este tipo de problemas sin la necesidad de dividir el problema en subproblemas, y sin la inclusión de áreas muertas entre las actividades (Tam indica en [Tam et al., 91] que la existencia de estas áreas es inevitable para la resolución de problemas tan complejos como el planteado). La solución que aportan Tam y Li al problema se muestra en la Figura 8.33. Las zonas desocupadas se muestran en color blanco.

Los autores no proporcionan ningún dato sobre dicha solución; ni distancias entre actividades ni costes del transporte de materiales; únicamente el valor de la función objetivo para los layouts parciales con los que se generó la solución final. Para servir como referencia se trató de establecer las distancias entre las actividades a partir del gráfico de la solución publicada en [Tam et al., 91]. Se partió de la premisa de que determinadas actividades (17, 18, 27 y 28) son cuadradas, por lo que se puede conocer cuanto deben medir sus lados partiendo de sus áreas. A partir de este dato fue posible obtener la escala del gráfico de la



solución<sup>58</sup>. De esta manera se pudo calcular el coste del transporte de materiales entre las actividades así configuradas, obteniendo un valor de 19880 unidades<sup>59</sup>. Así mismo se determinó el tamaño de la planta necesaria para albergar las actividades dispuestas según dicha solución, resultando precisa una nave de 27,87 x 20,25, lo que se traduce en una superficie de 564,52 unidades de área. Dado que la suma de las áreas requeridas por las actividades es 358, el porcentaje de superficie desocupada es del 36,6%.

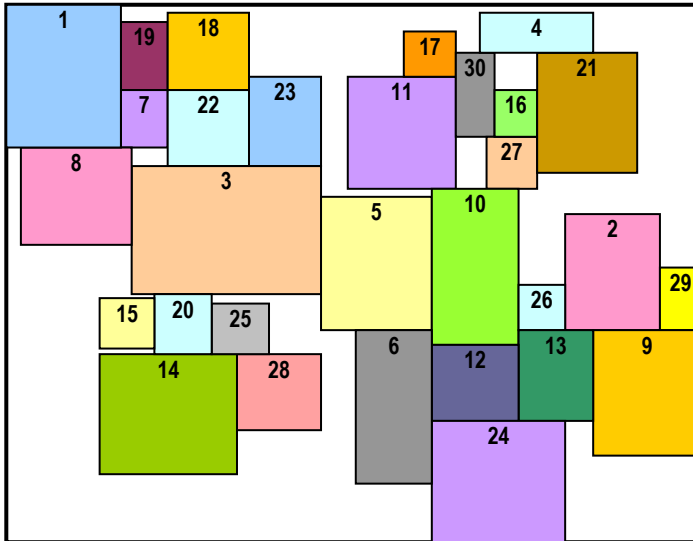


Figura 8.33: Solución al problema de Tam de 30 actividades propuesta en [Tam et al., 91].

Dado que Tam y Li no indican la forma del dominio de ubicación, se realizaron dos experimentos para resolver el problema mediante LAYAGEN G, el primero fijando el ratio de la planta en 1 (planta cuadrada), y el segundo dejando que el algoritmo determinara el ratio más adecuado siempre dentro del intervalo  $[0,5, 1]$ . Los parámetros empleados en ambos experimentos fueron los presentados en la Tabla 8.20.

En el primer caso se obtuvo como mejor resultado la distribución de la Figura 8.34, con un coste debido al flujo de materiales de 17809,38. En el segundo caso se obtuvo la distribución de ratio 0,76 y coste del transporte de materiales 17058,4 presentada en la Figura 8.39.

<sup>58</sup> Este método es forzosamente inexacto y parte de la suposición de que el gráfico de la solución fue elaborado respetando las escalas. No obstante, una vez obtenida la escala fue posible determinar las distancias entre los centros de las actividades, comprobando que, calculando a partir de ellas los valores de los costes del transporte de materiales de los layouts parciales, estos resultaron muy similares a los ofrecidos por los autores.

<sup>59</sup> Se ha empleado en este cálculo la métrica euclídea.

LG1		
Acrónimo	Nombre del parámetro	Tam
n	Tamaño de la población	30
Pc	Probabilidad de cruce	0,95
Pm	Probabilidad de mutación	0,80
Ng	Número de generaciones	2000
Cr	Coficiente relacional	90000
Cg	Coficiente geométrico	300000
Eg	Exponente geométrico	1
Pg	Precisión geométrica	4
	Mutación geométrica	activa
Pmg	Prob. de mutación geométrica	0,92
	Intensificación de búsqueda	activa
Fib	Frecuencia de intensificación	400
lib	Intensidad de intensificación	4
	Aleatoriedad de intensificación	inactiva
	Estrategia elitista	activa
le <sub>1</sub>	Intensidad de elitismo	4
	Intensificación en la élite	activa

LG2		
Acrónimo	Nombre del parámetro	Tam
n	Tamaño de la población	30
Pc	Probabilidad de cruce	0,90
Pm	Probabilidad de mutación	0,60
Ng	Número de generaciones	1500
Cr	Coficiente relacional	1
Cg	Coficiente geométrico	100000
	Métrica (Manhattan/euclídea)	Euclídea
	Estrategia elitista	activa
le <sub>2</sub>	Intensidad de elitismo	4
	Exploración de ratios	----
	Ratio recomendado en Fase 1	----
Na	Número de ejec. por árbol	10
p	Exp. función penalizadora	5

Tabla 8.20: Parámetros de ejecución para el problema de Tam de 30 actividades.




Figura 8.34: Solución al problema de Tam de 30 actividades con planta de ratio 1.




Figura 8.35: Solución al problema de Tam de 30 actividades con planta de ratio 0,95.

Además de la disminución del coste del transporte de materiales que suponen las soluciones obtenidas mediante LAYAGEN G, es destacable la elevada calidad geométrica de las mismas. La total compacidad de las distribuciones, sin la presencia de áreas muertas, redonda en una disminución de la distancia entre las actividades y, por lo tanto, del coste del transporte de materiales entre ellas. Además, se disminuye el tamaño de la nave necesaria para albergar el proceso productivo, siendo un 63,4% de la necesaria para contener la distribución obtenida mediante el método jerárquico de Tam y Li (Figura 8.36). Todo esto se logra respetando las estrictas restricciones geométricas impuestas en el problema original.

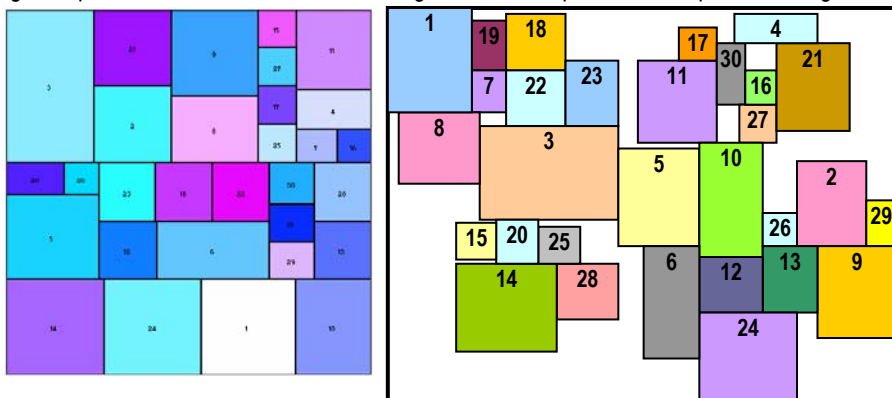


Figura 8.36: Representación de las proporciones de los dominios de ubicación de las distribuciones del problema de Tam de 30 actividades obtenidas mediante LAYAGEN G y el método jerárquico de Tam y Li.

## **8.5. Resolución de un problema con requerimientos formales diversos (E3)**

En el apartado anterior se han resuelto mediante LAYAGEN G problemas empleados de manera habitual para establecer comparaciones entre los rendimientos de diferentes métodos de resolución del problema de distribución en planta. En el ámbito de los problemas de actividades de área desigual, el de Armour y Buffa es quizá el más conocido y empleado.

Los problemas que se han podido recoger en la bibliografía presentan características diferenciadas en cuanto al número de actividades, la mayor o menor uniformidad en las áreas requeridas por cada actividad y la mayor o menor rigidez de los requerimientos geométricos. En general, los problemas estudiados suelen restringir en la misma medida todas las actividades y considerar que es deseable que el área asignada a todas ellas se aproxime lo máximo posible a un cuadrado (por ejemplo en [Tate et al., 95]).

Esta es una limitación recurrente en los problemas localizados, salvo en el problema de Tam y Li de 30 actividades. En realidad la forma de las áreas que requieren las actividades pueden estar más o menos alejadas de un cuadrado, y ser más o menos estrictas en unos casos que en otros. Así, en una misma distribución, una actividad concreta puede requerir un gran espacio esbelto y con poca tolerancia dimensional, otra necesitar un espacio reducido con gran tolerancia formal que le permite adoptar diversas formas y otra, por ejemplo, requerir de una forma ligeramente alargada en sentido vertical y sin tolerancia en la esbeltez.

El método desarrollado en la presente tesis permite localizar distribuciones en las que las áreas y las restricciones geométricas de las actividades sean diferentes entre sí, tanto en forma como grado de tolerancia. El potencial geométrico del árbol de cortes servirá como indicador de la capacidad de los árboles estudiados para generar distribuciones adecuadas, incluso en los casos de actividades muy diferentes en forma, tamaño y restricciones. Para demostrar esta capacidad se ha considerado conveniente la resolución de un problema generado *ad hoc*, que ponga a prueba la aptitud del algoritmo. Las características de dicho problema deberán ser: complejidad, número elevado de actividades, actividades de áreas muy diferentes, necesidad de formas muy diferentes de las diversas actividades y restricciones formales con distintos grados de tolerancia.

### **8.5.1 El problema planteado**

El problema planteado es la distribución en una planta de ratio alto-ancho 0,9, de 40 actividades de orientación libre. El número de actividades dobla el del problema de Armour y Buffa. Las áreas, ratios máximos y ratios mínimos de los departamentos se han generado de forma aleatoria, introduciendo posteriormente ciertas modificaciones para lograr que el problema cumpliera los objetivos para los que se plantea. Los datos completos del mismo se exponen en la Tabla 8.21.

En la Figura 8.37 se han representado gráficamente las áreas requeridas por las 40 actividades. El dibujo se ha realizado a escala para poder apreciar las significativas diferencias en las áreas necesarias para cada actividad. Por ejemplo, la actividad 19 requiere 698,5 unidades de área para su desempeño, mientras que la actividad 32 sólo 18,56. Además, cada actividad se ha representado con las formas extremas que pueden adoptar. En algunos casos se requiere que las formas sean prácticamente cuadradas (por ejemplo las

actividades 12 y 13), en otros es necesario que la forma sea esbelta (por ejemplo las actividades 14, 17, 19 ó 40). Existen actividades con tolerancias formales elevadas (como las actividades 1, 4 ó 14) y otras estrictas (2,13 ó 38) <sup>60</sup>.

Todas las actividades son de orientación libre. Aunque en la representación de la Figura 8.37 adoptan una orientación predominantemente horizontal, son válidas también las configuraciones en las que adopten orientaciones verticales. La Tabla 8.22 muestra el volumen y coste del transporte de materiales entre las diferentes actividades.

<b>Problema con requerimientos formales diversos (E3)</b>				
Número de actividades:		40		
Ratio fijo del dominio		0,9		
<b>Actividades</b>				
<i>Número</i>	<i>Area</i>	<i>Orientación</i>	<i>Ratio mínimo</i>	<i>Ratio máximo</i>
1	56,843	Libre	0,51	1
2	79,943	Libre	0,56	0,7
3	58,103	Libre	0,57	1
4	129,315	Libre	0,49	1
5	138,165	Libre	0,47	0,65
6	491,470	Libre	0,76	1
7	297,180	Libre	0,69	1
8	51,800	Libre	0,73	0,98
9	126,968	Libre	0,76	0,92
10	156,980	Libre	0,31	0,43
11	80,645	Libre	0,34	0,49
12	151,130	Libre	0,83	1
13	38,735	Libre	0,83	1
14	50,165	Libre	0,15	0,33
15	68,150	Libre	0,45	0,75
16	37,463	Libre	0,8	1
17	120,968	Libre	0,32	0,46
18	55,770	Libre	0,67	0,92
19	698,500	Libre	0,25	0,41
20	80,290	Libre	0,66	0,98
21	191,770	Libre	0,62	1
22	70,300	Libre	0,3	0,44
23	31,450	Libre	0,57	0,69
24	144,525	Libre	0,81	1
25	51,118	Libre	0,59	0,78
26	60,643	Libre	0,66	0,89
27	49,513	Libre	0,28	0,41
28	147,955	Libre	0,73	1
29	214,650	Libre	0,29	0,38
30	88,245	Libre	0,68	1
31	52,725	Libre	0,42	0,55
32	18,560	Libre	0,55	0,79
33	152,440	Libre	0,55	0,85
34	50,350	Libre	0,42	0,52
35	64,463	Libre	0,68	0,98
36	126,140	Libre	0,69	1
37	26,270	Libre	0,39	0,53
38	151,340	Libre	0,41	0,5
39	87,945	Libre	0,54	0,79
40	203,645	Libre	0,3	0,41

Tabla 8.21: Datos del problema con requerimientos formales diversos.

<sup>60</sup> Es necesario recordar que el empleo del ratio alto-ancho como medida de la forma de las áreas de las actividades provoca la no existencia de linealidad entre la diferencia de ratios y la diferencia de formas. Así, una diferencia de ratios de 0,1 cuando estos adoptan valores cercanos a la unidad, se traduce en figuras más parecidas entre sí que si dichos ratios poseen valores alejados de la unidad.

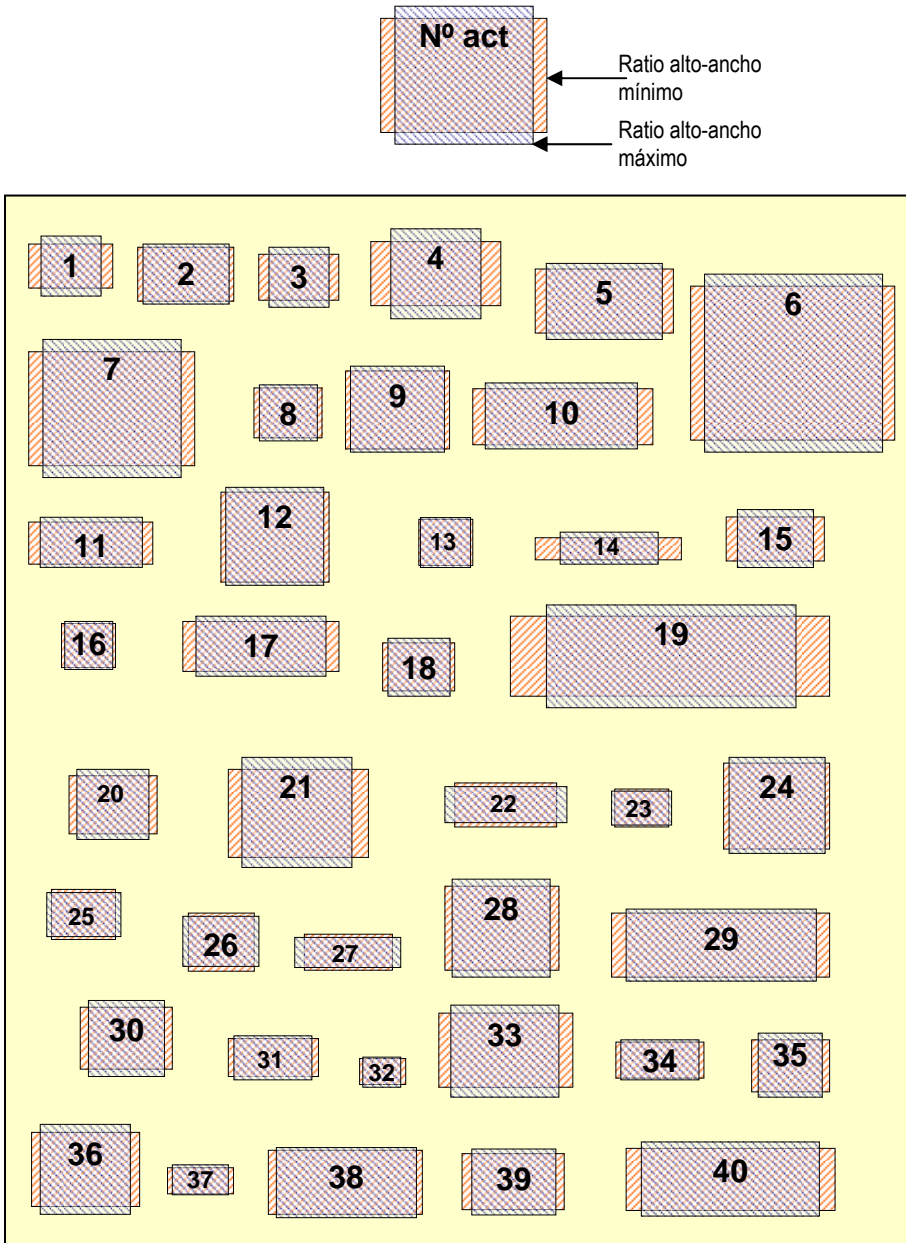


Figura 8.37: Representación a escala de las actividades del problema propuesto y sus tolerancias formales.

A1	A2	A3	A4	A5	A6	A7	A8	A9	A10	A11	A12	A13	A14	A15	A16	A17	A18	A19	A20	A21	A22	A23	A24	A25	A26	A27	A28	A29	A30	A31	A32	A33	A34	A35	A36	A37	A38	A39	A40	
A1	*	10	9	20	10	11	7	11	8	15	22	6	2	15	13	8	12	11	7	9	3	6	14	9	17	12	3	16	2	15	13	3	5	11	15	13	13	2	11	14
A2		*	10	4	7	16	14	6	15	2	14	13	6	14	15	4	12	10	15	14	17	5	4	37	14	16	15	10	14	14	9	7	10	6	10	13	9	8	14	10
A3			*	15	16	7	16	9	11	11	5	7	37	8	17	4	5	12	14	17	5	7	5	12	13	14	11	13	6	14	10	4	11	9	9	6	6	15	8	43
A4				*	3	11	17	5	9	11	4	5	5	14	14	16	13	11	22	4	3	7	42	3	13	11	13	9	3	12	12	5	12	8	26	15	16	2	27	7
A5					*	14	14	7	16	4	12	80	16	16	6	7	3	13	35	5	14	16	12	14	16	6	14	6	50	10	1	2	3	7	7	13	13	6	4	7
A6						*	70	8	8	11	10	12	15	12	7	16	9	11	9	3	2	17	16	15	8	8	9	14	8	10	13	12	7	7	12	7	2	16	5	8
A7							*	3	2	13	5	6	6	16	16	4	51	7	11	4	15	6	7	10	9	6	12	15	2	8	16	16	10	3	14	13	9	13	15	9
A8								*	17	13	11	11	9	6	12	4	5	14	16	6	4	3	15	9	6	6	14	5	10	13	9	6	4	25	15	7	5	6	6	4
A9									*	0	16	14	17	3	8	13	13	62	5	15	19	10	10	16	10	17	8	4	4	4	11	16	4	19	10	14	15	39	12	8
A10										*	3	15	16	7	10	12	13	2	5	7	6	2	12	17	5	2	12	14	2	2	9	7	9	7	8	9	10	12	7	11
A11											*	5	17	4	16	4	15	11	12	9	3	3	7	11	10	15	6	3	8	11	63	4	14	16	9	7	10	16	11	16
A12												*	13	7	11	14	12	5	3	9	13	3	14	8	2	16	4	16	4	6	13	9	4	14	5	7	3	15	15	2
A13													*	9	12	9	4	3	42	5	11	14	14	4	11	10	4	9	7	3	43	4	9	4	16	4	8	9	10	14
A14														*	14	3	12	8	3	4	3	15	5	10	16	5	14	11	12	56	5	14	8	14	8	11	17	15	10	5
A15															*	12	6	17	8	17	32	2	4	42	14	10	15	10	16	14	13	8	10	16	7	6	3	9	4	11
A16																*	10	9	76	11	7	17	12	16	11	16	2	10	12	15	15	9	10	3	12	1	5	7	4	10
A17																	*	10	6	16	10	12	7	7	14	4	10	4	9	14	9	5	7	14	4	10	4	15	13	5
A18																		*	8	4	13	14	12	9	6	7	9	14	2	2	12	13	15	14	8	14	14	15	6	16
A19																			*	14	6	16	8	9	11	7	3	105	16	5	15	12	90	12	12	11	4	16	8	5
A20																				*	12	16	34	10	5	9	15	9	16	16	10	16	8	15	17	15	5	13	2	
A21																					*	28	2	4	5	3	11	17	10	8	5	14	93	4	17	6	17	7	6	4
A22																						*	12	16	6	8	5	13	13	2	16	13	35	8	30	16	8	9	9	10
A23																							*	10	14	13	9	3	9	8	12	11	9	16	5	16	6	2	3	14
A24																								*	2	10	11	10	11	12	5	11	15	6	4	13	14	11	4	10
A25																								*	16	10	16	6	14	7	10	13	5	13	8	12	10	14	70	
A26																									*	11	5	4	15	4	15	9	3	9	15	11	15	17	10	
A27																									*	9	9	12	6	14	9	4	6	4	16	10	8	16	10	8
A28																									*	10	11	30	17	7	13	7	13	10	9	32	14			
A29																										*	7	3	14	5	7	3	6	10	9	11	15			
A30																										*	7	5	14	4	3	7	14	7	3	5				
A31																										*	4	10	14	4	15	4	10	9	5					
A32																										*	12	6	10	4	5	14	17	9						
A33																										*	15	4	7	13	17	6	12							
A34																										*	7	10	8	12	4	5								
A35																										*	3	15	4	15	10									
A36																										*	5	62	3	54										
A37																										*	3	5	13											
A38																										*	3	9												
A39																										*	3													
A40																										*														

Tabla 8.22: Matriz de volumen\*coste por unidad de distancia del transporte de materiales entre actividades en el experimento E3.

### 8.5.1.1 Medición de la complejidad del problema

La resolución del problema planteado posee un nivel de dificultad superior a los anteriores. La dominancia de flujo de la matriz de transporte es 91,1, un valor inferior al del resto de problemas, lo cual indica que la agrupación de actividades por las afinidades marcadas por dicha matriz es menos clara que en los demás casos. A partir de dicho valor y para un problema de 40 actividades se puede establecer que el porcentaje de complejidad es del 87,8%. En la Figura 8.38 se realiza una comparación entre la complejidad de los diferentes problemas.

Problema	Dominancia de flujo	Complejidad
Francis y White	264,7	29,4%
Armour y Buffa	253,6	45,8%
Tam 30	111	82,5%
Problema actual	91,1	87,8%




Figura 8.38: Porcentajes de complejidad de los problemas resueltos.

### 8.5.2 Descripción del experimento

El procedimiento de experimentación consistió en localizar un árbol de cortes mediante LG1, y aplicar LG2 diez veces sobre dicho árbol para obtener la mejor distribución posible de él. Este proceso se llevó a cabo diez veces empleando siempre los mismos parámetros, tanto para LG1 como para LG2. Dichos parámetros se ofrecen en la Tabla 8.23.

En LG1 se activó la mutación geométrica cuando el grado de convergencia de la población superó el 0,92, y se realizaron intensificaciones locales de búsqueda cada 500 generaciones sobre 5 individuos; se mantuvo un grupo de 4 individuos élite que eran sometidos a búsqueda local al entrar en el buffer. En LG2 se siguió la misma estrategia elitista.

Además de las 10 repeticiones del experimento reseñado en la Tabla 8.23, se realizó uno más de manera única. En él se mantuvieron los mismos parámetros pero se consideró que el ratio de la planta no estaba fijado a priori y que podía variar entre 0,5 y 1.



LG1			LG2		
Acrónimo	Nombre del parámetro	E3	Acrónimo	Nombre del parámetro	E3
n	Tamaño de la población	30	n	Tamaño de la población	30
Pc	Probabilidad de cruce	0,95	Pc	Probabilidad de cruce	0,90
Pm	Probabilidad de mutación	0,80	Pm	Probabilidad de mutación	0,60
Ng	Número de generaciones	3500	Ng	Número de generaciones	3000
Cr	Coefficiente relacional	90000	Cr	Coefficiente relacional	1
Cg	Coefficiente geométrico	100000	Cg	Coefficiente geométrico	100000
Eg	Exponente geométrico	1		Métrica	Manhattan
Pg	Precisión geométrica	4		Estrategia elitista	activa
	Mutación geométrica	activa	le <sub>2</sub>	Intensidad de elitismo	4
Pmg	Prob. de mutación geométrica	0,92		Exploración de ratios	----
	Intensificación de búsqueda	activa		Ratio recomendado en	----
Fib	Frecuencia de intensificación	500	Na	Número de ejec. por árbol	10
lib	Intensidad de intensificación	5	p	Exp. función penalizadora	5
	Aleatoriedad de intensificación	inactiva			
	Estrategia elitista	activa			
le <sub>1</sub>	Intensidad de elitismo	4			
	Intensificación en la élite	activa			

Tabla 8.23: Parámetros de ejecución empleados en el experimento E3.

### 8.5.3 Exposición y análisis de los resultados de los experimentos

Tras las 10 ejecuciones los resultados obtenidos se resumieron en la Tabla 8.24. De cada ejecución se recogió la mejor distribución (por tanto 10 distribuciones por experimento), calculándose el coste del flujo de materiales y el coste geométrico medios, máximos y mínimos. Se calculó, además, la generación en la que, en promedio, se localizó dicha distribución en cada experimento. Una exposición detallada de los mismos puede consultarse en el ANEXO 1.

En todos los casos fue posible localizar mediante LG1 un árbol de cortes con potencial geométrico nulo, lo que garantiza la existencia de distribuciones geoméricamente aceptables derivadas de dichos árboles. En todas las ejecuciones se localizaron distribuciones que cumplieran las restricciones geométricas, no obstante, el número medio de distribuciones geoméricamente aceptables por cada ejecución de LG2 fue de 33,69, lo que denota la dificultad del problema planteado. En promedio fueron necesarias 1067,6 generaciones de LG1 y 1194,8 de LG2 para localizar las mejores distribuciones. Es destacable que muchas de los individuos óptimos localizados se obtienen en generaciones próximas a valores cercanos a múltiplos de 500 (ver ANEXO1). Esto es debido a que en estas generaciones actúa el proceso de intensificación de la búsqueda, lo que da lugar a la aparición de óptimos que mejoran en las generaciones siguientes.

La mejor de las distribuciones obtenidas en todas las ejecuciones es la presentada en la Figura 8.39. Se obtuvo en la tercera ejecución y el coste asociado al flujo de materiales entre las actividades de la misma es 326623,53 unidades. Las mejores distribuciones de las restantes ejecuciones y sus costes asociados se muestran en la Figura 8.40.

	E3-1	E3-2	E3-3	E3-4	E3-5
Coste flujo materiales distribución óptima / actividades factibles	339092,25 / 40	341141,47 / 40	326623,53 / 40	346739,67 / 40	336566,41 / 40
Coste flujo materiales medio	342632,41	341346,13	328043,18	349434,73	337513,46
Coste flujo materiales máximo	352681,57	346431,28	334543,38	361239,16	339892,53
Coste flujo materiales mínimo	338562,89	334401,16	326177,06	330199,64	336566,41
Coste geométrico medio	1,48	1,37	1,29	1,89	1,58
Coste geométrico máximo	2,72	2,68	2,04	2,68	2,96
Coste geométrico mínimo	0,98	0,98	0,98	0,98	0,98
Nº medio de actividades válidas	34,3	35,60	34,40	30,30	34,60
Nº máximo de actividades válidas	40	40	40	40	40
Nº mínimo de actividades válidas	24	22	24	22	25
Generación del óptimo media	1067,6	920,3	1780,4	1299,6	916,7

	E3-6	E3-7	E3-8	E3-9	E3-10	Medias
Coste flujo materiales distribución óptima / actividades factibles	347506,38 / 40	334837,98 / 40	332107,48 / 40	343528,21 / 40	333782,62 / 40	<b>338092,64 / 40</b>
Coste flujo materiales medio	348544,81	336351,19	333147,67	343771,35	334601,28	<b>339538,62</b>
Coste flujo materiales máximo	354907,37	345263,73	338597,15	349364,63	338190,47	<b>346111,13</b>
Coste flujo materiales mínimo	342294,93	334837,98	330399,16	336373,91	332699,36	<b>334251,25</b>
Coste geométrico medio	1,75	1,63	1,18	1,96	1,34	<b>1,55</b>
Coste geométrico máximo	2,67	2,74	1,54	3,67	2,58	<b>2,63</b>
Coste geométrico mínimo	0,98	0,98	0,98	0,98	0,98	<b>0,98</b>
Nº medio de actividades válidas	31,50	33,10	36,70	30,30	36,10	<b>33,69</b>
Nº máximo de actividades válidas	40	40	40	40	40	<b>40,00</b>
Nº mínimo de actividades válidas	23	23	32	21	24	<b>24,00</b>
Generación del óptimo media	1141,7	1441,3	1103,1	1147,8	1129,5	<b>1194,80</b>

Tabla 8.24: Resultados obtenidos en el experimento E3.

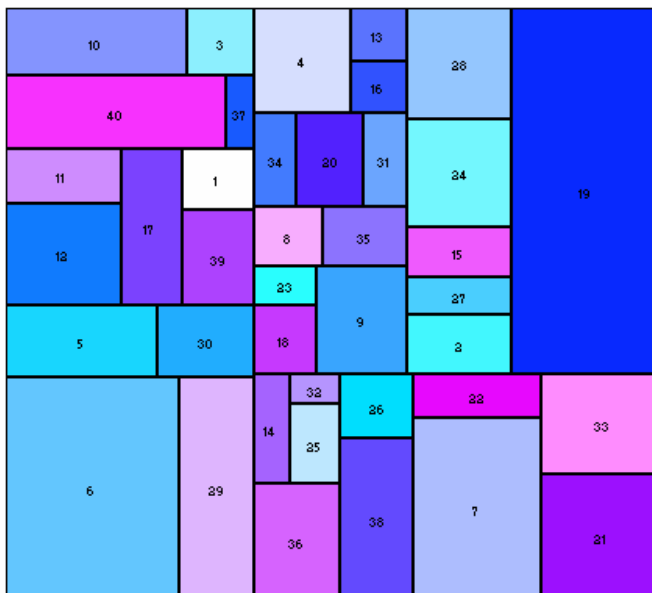


Figura 8.39: Representación de la mejor solución obtenida en el experimento E3. El coste asociado al flujo de materiales entre las actividades es 326623,48.

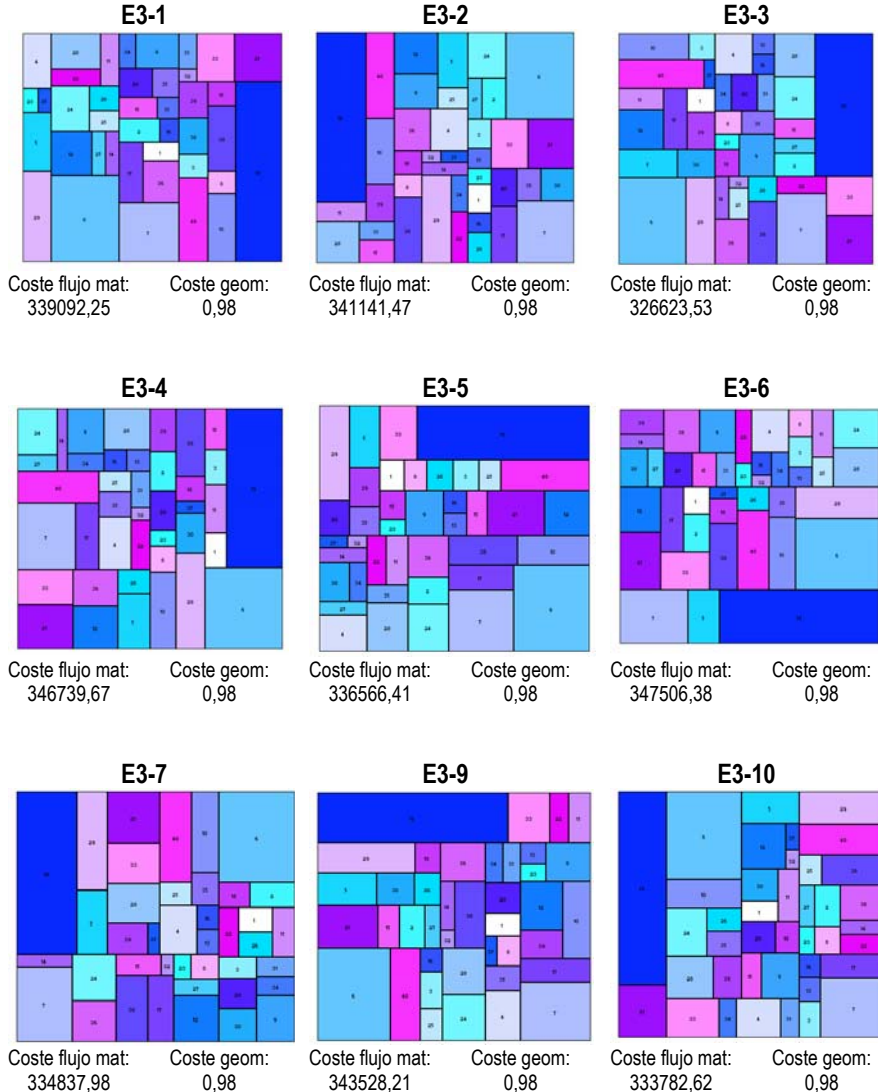


Figura 8.40: Mejores soluciones obtenidas en los experimentos E3.

Como se ha indicado, se realizó una ejecución sin fijar el ratio del dominio de ubicación de la planta, dejando oscilar éste en el intervalo  $[0,5, 1]$ . En este caso fue LG2 el encargado de localizar el ratio más adecuado al problema. La distribución obtenida como solución tuvo un coste geométrico de 0,98, correspondiente a una distribución de 40 actividades en la que todas cumplen los requerimientos geométricos. El coste asociado al transporte de materiales fue de 324274,16 unidades, lo que representa una disminución de 2349,37 unidades respecto a la mejor solución obtenida con ratio de planta fijo. El ratio alto-ancho de la planta que alberga dicha solución es 0,72 (ver Figura 8.41).




Figura 8.41: Representación de la mejor solución obtenida en el experimento E3 considerado de ratio de planta libre. El coste asociado al flujo de materiales entre las actividades es 324264,16.

# 9

## Conclusiones y trabajos futuros

## 9. CONCLUSIONES Y TRABAJOS FUTUROS

### 9.1. Conclusiones

Los experimentos llevados a cabo en el capítulo anterior han permitido validar las hipótesis que sirvieron de base para el desarrollo de la metodología propuesta:

- La **hipótesis 1** quedó validada al comprobar que, a la vista de los resultados, el empleo de una estrategia en dos fases resulta más eficaz que otro tipo de técnicas que no restringen la búsqueda a una zona determinada del espacio de soluciones. Una estructura bifásica en la que en la primera fase se realiza la agrupación de las actividades en una estructura de cortes, para lo que se consideran todos los criterios que posteriormente se emplearán en la medición de la bondad de las distribuciones, incluido el criterio geométrico, y con una segunda fase en la que se define la forma de dichos cortes.
- Ha podido determinarse también que la segunda fase está fuertemente determinada por el resultado obtenido en la primera. La limitación del espacio de búsqueda debe realizarse sobre una zona especialmente prometedora del campo de soluciones para no mermar las posibilidades de éxito en la solución del problema. Los experimentos llevados a cabo han demostrado que los resultados mejoran si se emplea una mayor cantidad de tiempo y recursos en la localización de una agrupación oportuna de las actividades, aún a costa de disminuir los dedicados a la segunda fase. Con esto quedó validada la **hipótesis 2**.
- Para poder realizar una agrupación adecuada de las actividades en la primera fase, era necesario establecer un indicador de la capacidad de un árbol de cortes para generar distribuciones, en las que las áreas asignadas a las actividades cumplieran los requerimientos geométricos impuestos en el problema. La hipótesis 3 planteaba que sería posible definir dicho indicador si se pudiera establecer alguna relación, entre la forma del dominio y la forma de los subdominios generados por la división del primero, empleando un procedimiento constructivo del indicador de carácter recursivo a semejanza del método empleado al construir las distribuciones mediante cortes del espacio. En este trabajo ha sido posible establecer la relación necesaria y construir a partir de ella el indicador buscado: el potencial geométrico del árbol de cortes. Con ello, y con la comprobación experimental de su eficacia, quedó demostrada la validez de la **hipótesis 3**.
- El cálculo del potencial geométrico de un árbol de cortes da por supuesto que, de entre los posibles cortes a realizar en cada uno de los nodos del árbol, se seleccionará el más conveniente para lograr una distribución adecuada desde el punto de vista geométrico (lo que se ha denominado *estrategia optimista*). La **hipótesis 4** de este trabajo planteaba que un algoritmo genético sería capaz de discriminar el tipo de corte óptimo en cada caso. Los resultados obtenidos refrendan dicha hipótesis.
- Por último, se ha comprobado que la introducción en el algoritmo de mecanismos

de intensificación de la búsqueda, el empleo de estrategias elitistas, y de forma general, la introducción de conocimiento específico del problema en el sistema de resolución, redundan en una mayor eficacia de la búsqueda. Con esto queda validada la **hipótesis 5**.

Se han cumplido, además, todos los objetivos planteados en el inicio de este trabajo.

- Se ha llevado a cabo un análisis del estado del arte de los modelos y métodos de resolución del problema de distribución en planta, de los diferentes enfoques y planteamientos, y de los resultados que obtienen con cada uno de ellos.
- Se ha estudiado el funcionamiento y el estado de las técnicas heurísticas y metaheurísticas empleadas en la resolución del problema de distribución en planta.
- Se ha realizado un profundo análisis de la teoría en la que se asientan los algoritmos evolutivos, y se han empleado dichos conocimientos para lograr una correcta y eficaz aplicación al problema en cuestión. Esto se ha materializado en la inclusión en el algoritmo genético desarrollado de nuevas formas de actuación de los operadores genéticos, la inclusión de etapas de búsqueda local intensiva, nuevas formas de elitismo, probabilidades de actuación de los operadores condicionadas a la convergencia de la población, etc.
- Se han definido nuevos indicadores de la calidad de los resultados obtenidos, fundamentalmente desde el punto de vista geométrico, que permiten salvar la incertidumbre existente en la primera fase del proceso de búsqueda de soluciones mediante el procedimiento que se plantea. El potencial geométrico del árbol de cortes permite realizar la agrupación de los ítems a distribuir mediante cortes de un dominio basándose en criterios geométricos, en una fase de resolución del problema en la que no se conoce la disposición que finalmente adoptarán los ítems o, incluso, la forma de la zona de ubicación. Los resultados experimentales indican la eficacia del potencial geométrico del árbol, como indicador de la posibilidad de que un determinado árbol pueda generar soluciones geoméricamente aceptables, tanto para un dominio de ubicación de forma fija como de forma libre. Asimismo, permite clasificar los árboles de corte en función de dicha capacidad, pudiendo introducir el indicador como parte de las funciones de evaluación de las técnicas heurísticas o metaheurísticas de búsqueda de soluciones.
- Se ha desarrollado una aplicación informática que implementa el algoritmo propuesto, y que permite automatizar el proceso de resolución de problemas de distribución aprovechando el potencial de cálculo de una red de ordenadores. Mediante este desarrollo se ha logrado agrupar en un único software todas las tareas a realizar en la resolución de un problema de distribución en planta mediante el método propuesto: introducción de datos, fijación de parámetros, ejecución de las dos fases del algoritmo, explotación de resultados... facilitando al planificador dichas tareas y agilizando el proceso de experimentación. Se ofrece información en tiempo real, gráfica y numéricamente, sobre la evolución de la población y valores de la función objetivo. Además, se permite el cambio de parámetros de ejecución del algoritmo (probabilidades de mutación y cruce, tamaño de la población, activación o desactivación del elitismo y la intensificación de la búsqueda local...) durante la ejecución.

En definitiva, se ha logrado el objetivo primordial del presente trabajo: se ha desarrollado un método eficiente que permite obtener distribuciones en planta de actividades industriales de elevada calidad bajo múltiples criterios, estableciendo como fundamental e irrenunciable, que el área asignada a las diferentes actividades cumplan estrictamente las restricciones geométricas impuestas.

Las distribuciones obtenidas mediante el método propuesto presentan una elevada calidad geométrica sin que ello suponga una disminución de la calidad medida bajo otros criterios. De hecho, en los experimentos realizados para comparar los resultados del método propuesto con los de otros procedimientos, se han mejorado las soluciones de la bibliografía tanto geoméricamente como desde el punto de vista del coste del transporte de materiales entre las actividades. En este sentido, se han aportado soluciones que mejoran las descritas en la bibliografía a los problemas de Francis y White, Armour y Buffa y Tam de 30 actividades. Se ha planteado, además, un nuevo problema de elevada complejidad geométrica y relacional que puede servir de test a futuros desarrollos en la línea del presente trabajo.

La determinación del potencial geométrico de un árbol de cortes conlleva realizar una cantidad importante de cálculos. El tiempo empleado en ello varía en función del número de actividades a distribuir y, en menor medida, del tamaño de los intervalos de validez geométrica de las actividades y del dominio de ubicación. Además, otro tipo de funcionalidades introducidas en el algoritmo LAYAGEN G como la intensificación de la búsqueda en el entorno de las soluciones, son grandes consumidoras de recursos informáticos. No obstante, el estudio de tiempos realizado y las aplicaciones a la resolución de problemas complejos llevada a cabo, ponen de manifiesto que los tiempos de ejecución en equipos informáticos de sobremesa de potencia media son perfectamente asumibles.

Por otra parte, el método propuesto es capaz de facilitar al proyectista la traslación a la realidad de la solución obtenida. La elevada calidad geométrica de las distribuciones obtenidas facilita el proceso de implantación de las mismas, dado que serán menores los ajustes necesarios para adaptarlas a las condiciones reales de la planta. El trazado de pasillos entre las actividades resultará sencillo a la vista de la estructura de los layouts generados; esta tarea es mucho más compleja en soluciones obtenidas mediante procedimientos basados en la discretización del dominio de partida.

Otro aspecto que facilita la tarea al planificador es la poca sensibilidad de los resultados obtenidos a una parametrización exhaustiva del algoritmo. Aunque no es posible establecer con carácter general los valores de los parámetros en la aplicación de los algoritmos genéticos al problema de la distribución en planta, LAYAGEN G ha demostrado una elevada robustez en este aspecto, que hace innecesario un ajuste fino de dichos parámetros. El estudio llevado a cabo proporciona órdenes de magnitud de los valores de los mismos que, salvo excepciones muy concretas, han resultado válidas para problemas de muy diversos tipos.

Los beneficios obtenidos del empleo del método presentado no serán sólo económicos. Una distribución ajustada debe contemplar entre sus criterios el bienestar, las condiciones laborales y la salud de los trabajadores. Además, la disminución de los costes productivos suele deberse, aunque no es el único motivo, a un menor consumo de energía en procesos de manutención y acopio de materiales, lo que supone indirectamente un menor coste



medioambiental.

## **9.2. Trabajos futuros**

Durante el desarrollo del presente trabajo se han detectado aspectos del mismo que podrían ser objeto de estudio y profundización en futuros desarrollos. Algunos de ellos se exponen a continuación.

El potencial geométrico del árbol de cortes definido en este trabajo es válido únicamente para dominios de ubicación rectangulares, en los que los ítems a distribuir son también rectangulares. Podría resultar de interés extender el ámbito de aplicación a dominios no rectangulares y en los que pueden existir áreas internas restringidas. Además, puede resultar de interés extender el procedimiento descrito al problema dinámico de distribución en planta, a las distribuciones multiplanta y a las tridimensionales.

El potencial geométrico del árbol de cortes y el algoritmo desarrollado pueden ser fácilmente adaptados para su empleo en otros ámbitos. Por ejemplo: la distribución de un conjunto de objetos que ocupan un área conocida en el interior de un objeto mayor (dominio), es una tarea común a diversos tipos de problemas. El envase y embalaje, la carga de contenedores de transporte, el almacenamiento, el corte de piezas de tela, etc., son ejemplos de problemas en cuyo planteamiento subyace la misma estructura lógica, distribuir pequeños ítems dentro de un ítem mayor respetando ciertas restricciones [Green, 89; Dyckhoff, 90; Islier, 98]. Los algoritmos genéticos y los árboles de cortes son empleados frecuentemente para resolver dichos problemas [Jakobs, 96; De la Fuente et al., 99], así pues, el potencial geométrico del árbol de cortes y el empleo del algoritmo propuesto en este trabajo sometido a ligeras modificaciones, se presentan prometedoras herramientas en dichos ámbitos.

Por otra parte, las funcionalidades incluidas en el algoritmo genético (las nuevas formas de actuación de los operadores genéticos, la inclusión de etapas de búsqueda local intensiva, los conjuntos de individuos élite de tamaño variable, las probabilidades de actuación de los operadores condicionadas a la convergencia de la población, etc.), que aumentan la eficacia del proceso, pueden ser adaptadas a cualquier algoritmo genético empleado en otros ámbitos. De hecho, esto se ha hecho ya efectivo en un algoritmo para la generación de planes de rotación de trabajadores en puestos de trabajo en cadena, para la minimización de los efectos perjudiciales de los movimientos repetitivos sobre los miembros del cuerpo [Aparisi-Navarro, 05].

Se considera necesario además, transferir los resultados de esta investigación tanto a la docencia, como a la sociedad, y su traslado a la comunidad científica mediante la publicación de los resultados.



# 10

**ANEXO 1**  
**Resultados completos de los experimentos realizados**

## 10. RESULTADOS COMPLETOS DE LOS EXPERIMENTOS REALIZADOS

### 10.1. EXPERIMENTOS DE PARAMETRIZACIÓN (E1)

#### 10.1.1 Resultados del experimento E1-1

**Árboles de corte: valores medios de los mejores árboles obtenidos tras 10 ejecuciones**

Coste flujo materiales medio:	1174,14
Coste flujo materiales máximo:	1212,81
Coste flujo materiales mínimo:	1140,26
Coste geométrico medio:	0
Coste geométrico máximo:	0
Coste geométrico mínimo:	0
Generación del óptimo media:	1377,3

**Datos del mejor árbol localizado en cada ejecución**

Ejecución	Generación	Coste total	Coste mater.	Coste geom.
1	827	1175,14	1175,14	0
2	2703	1205,1	1205,1	0
3	1429	1212,81	1212,81	0
4	1792	1140,26	1140,26	0
5	294	1166,97	1166,97	0
6	2058	1174,04	1174,04	0
7	626	1177,01	1177,01	0
8	2966	1143,69	1143,69	0
9	617	1167,22	1167,22	0
10	461	1179,14	1179,14	0

**Codificación del mejor árbol localizado en cada ejecución**

Ejecución	Codificación
1	6 9 4 2 21 18 10 14 19 3 17 12 15 24 7 8 23 25 27 26 1 5 20 28 13 31 22 32 29 34 35 33 11 16 37 30 36 38
2	3 19 18 1 11 16 5 13 10 14 15 25 2 4 20 22 27 6 9 24 30 26 21 31 12 17 33 32 7 29 8 35 36 28 23 34 37 38
3	5 1 16 11 4 2 19 23 10 14 8 7 9 26 21 6 28 13 27 20 12 17 18 30 25 3 32 24 22 29 33 34 31 15 37 36 35 38
4	7 8 5 1 10 14 15 22 21 20 2 4 13 9 12 17 6 18 29 25 16 11 27 23 3 19 30 26 31 28 35 24 34 33 36 32 37 38
5	13 1 14 10 3 22 12 17 11 16 25 24 21 15 18 19 6 5 4 2 29 9 23 27 32 31 7 8 20 34 35 30 33 26 28 36 37 38
6	1 5 7 8 12 10 2 4 15 13 11 16 6 18 14 9 25 28 19 24 22 20 30 3 26 17 33 29 32 23 27 31 35 34 36 21 38 37
7	17 12 13 1 5 15 23 3 14 10 4 2 16 11 6 9 8 7 20 29 19 26 21 31 24 25 27 22 32 33 34 28 35 36 30 18 38 37
8	2 4 8 7 22 20 21 23 1 5 19 3 16 11 9 13 6 18 17 12 24 29 25 15 14 10 28 33 30 27 35 32 31 26 36 34 37 38
9	8 7 2 4 17 12 21 20 19 3 1 5 13 9 11 16 6 18 10 14 30 27 23 28 29 26 22 24 15 33 34 25 32 36 37 35 31 38
10	3 19 14 10 2 4 6 5 8 7 20 25 22 15 9 13 17 12 27 21 23 26 18 1 16 11 28 29 32 30 34 35 24 31 33 36 38 37

## 10.1.2 Resultados del experimento E1-2

### Árboles de corte: valores medios tras 10 ejecuciones

Coste flujo materiales medio:	1173,73
Coste flujo materiales máximo:	1213,83
Coste flujo materiales mínimo:	1139,08
Coste geométrico medio:	0
Coste geométrico máximo:	0
Coste geométrico mínimo:	0
Generación del óptimo media:	1406,3

### Resultados de cada ejecución

Ejecución	Generación	Coste total	Coste mater.	Coste geom.
1	720	1178,45	1178,45	0
2	2766	1179,69	1179,69	0
3	658	1164,93	1164,93	0
4	2780	1178,6	1178,60	0
5	1905	1176,82	1176,82	0
6	192	1153,64	1153,64	0
7	1376	1213,83	1213,83	0
8	959	1180,06	1180,06	0
9	1629	1139,08	1139,08	0
10	1078	1172,27	1172,27	0

### Codificación del mejor árbol localizado en cada ejecución

Ejecución	Codificación del mejor árbol de la ejecución
1	1 15 19 3 9 13 8 7 23 17 10 14 21 12 18 5 2 4 24 20 6 28 16 11 27 26 29 30 31 34 25 32 35 22 33 37 38 36
2	14 9 5 1 19 3 10 12 2 4 22 18 16 11 17 27 7 8 25 23 20 29 15 13 30 24 32 21 28 34 6 31 36 26 33 35 37 38
3	19 3 13 9 17 12 16 11 7 8 2 4 14 10 25 20 18 22 27 15 24 23 28 6 5 1 32 26 29 21 34 33 31 30 37 35 38 36
4	3 18 1 5 8 7 20 23 10 14 25 15 21 19 9 6 13 22 26 29 24 28 16 11 17 12 4 2 32 33 27 35 34 31 36 37 30 38
5	11 16 19 3 18 1 4 2 23 13 10 14 24 9 7 8 22 27 26 15 21 25 28 20 5 6 30 29 12 17 33 32 35 31 36 34 38 37
6	2 4 5 1 7 8 22 13 19 21 12 17 14 10 27 3 9 6 29 18 20 23 28 15 11 16 33 24 25 31 30 35 26 34 32 37 36 38
7	11 16 17 12 22 21 6 20 5 1 13 9 7 8 18 3 14 10 25 15 27 24 4 2 30 23 32 19 31 33 28 34 26 29 36 35 37 38
8	20 18 12 17 9 5 4 2 14 10 24 6 8 7 16 11 13 1 27 21 30 26 19 3 22 15 25 23 31 32 34 35 29 28 36 33 37 38
9	5 9 13 1 10 14 23 3 17 12 16 11 4 2 7 8 26 22 18 6 24 15 19 27 28 20 25 21 30 33 32 35 36 34 31 37 29 38
10	14 10 1 18 5 13 9 6 22 19 15 23 12 17 11 16 7 8 2 4 27 28 21 26 29 20 24 33 30 34 25 35 32 3 31 36 38 37

### 10.1.3 Resultados del experimento E1-3

#### Árboles de corte: valores medios tras 10 ejecuciones

Coste flujo materiales medio:	1225,2
Coste flujo materiales máximo:	1433,4
Coste flujo materiales mínimo:	1149,71
Coste geométrico medio:	0
Coste geométrico máximo:	0
Coste geométrico mínimo:	0
Generación del óptimo media:	2023,6

#### Resultados de cada ejecución

Ejecución	Generación	Coste total	Coste mater.	Coste geom.
1	718	1153,12	1153,12	0
2	1608	1201,74	1201,74	0
3	3000	1196,47	1196,47	0
4	432	1383,05	1383,05	0
5	2742	1433,4	1433,4	0
6	1234	1171,74	1171,74	0
7	2025	1149,71	1149,71	0
8	2897	1222,8	1222,8	0
9	2814	1174,87	1174,87	0
10	2766	1165,09	1165,09	0

#### Codificación del mejor árbol localizado en cada ejecución

Ejecución	Codificación del mejor árbol de la ejecución
1	12 17 5 1 14 10 15 23 7 8 3 19 9 6 21 24 20 25 22 18 28 26 4 2 29 32 27 33 11 16 30 13 34 31 37 36 38 35
2	15 3 2 4 11 16 10 14 5 1 18 20 9 13 21 24 28 23 7 8 19 22 6 25 30 26 33 31 12 17 32 34 27 35 37 29 38 36
3	10 14 13 1 12 17 6 5 3 21 9 24 8 7 4 2 22 15 27 20 30 18 11 16 29 32 19 28 25 33 26 35 34 36 23 31 37 38
4	10 12 8 7 9 13 11 18 4 2 25 16 6 5 1 15 21 24 23 14 26 27 19 3 28 17 30 33 22 20 35 31 29 34 32 37 38 36
5	5 9 13 1 6 21 11 17 16 20 8 7 12 10 23 26 28 25 4 2 14 15 18 22 30 19 27 31 24 34 29 32 36 35 3 33 37 38
6	1 5 2 4 14 10 9 13 3 19 17 12 15 23 24 18 11 16 21 6 30 22 25 28 26 29 33 27 8 7 32 34 35 20 37 31 38 36
7	1 15 8 7 11 16 19 3 9 13 12 17 14 10 22 20 5 18 27 25 29 6 2 4 28 32 26 21 33 31 24 35 36 30 34 37 38 23
8	5 1 9 13 8 7 16 11 15 21 18 19 3 14 17 26 20 23 6 29 27 10 2 4 30 25 31 12 33 32 34 28 24 22 36 37 38 35
9	15 5 12 17 14 10 13 9 1 18 7 8 20 26 2 4 3 23 16 11 19 28 22 31 21 6 29 32 33 25 30 24 35 27 36 34 38 37
10	2 4 5 6 8 7 1 18 10 14 16 11 3 19 23 20 25 15 28 22 29 12 9 13 21 30 27 31 24 33 32 26 36 17 37 34 38 35

## 10.1.4 Resultados del experimento E1-4

### Árboles de corte: valores medios tras 10 ejecuciones

Coste flujo materiales medio:	1195,45
Coste flujo materiales máximo:	1273,57
Coste flujo materiales mínimo:	1149,71
Coste geométrico medio:	0
Coste geométrico máximo:	0
Coste geométrico mínimo:	0
Generación del óptimo media:	1546

### Resultados de cada ejecución

Ejecución	Generación	Coste total	Coste mater.	Coste geom.
1	307	1158,76	1158,76	0
2	1439	1213	1213	0
3	1722	1149,71	1149,71	0
4	531	1152,4	1152,4	0
5	2837	1236,69	1236,69	0
6	1836	1195,25	1195,25	0
7	1381	1273,57	1273,57	0
8	2550	1235,08	1235,08	0
9	1378	1168,83	1168,83	0
10	1479	1171,23	1171,23	0

### Codificación del mejor árbol localizado en cada ejecución

Ejecución	Codificación del mejor árbol de la ejecución
1	17 12 8 7 9 6 11 16 20 22 1 15 13 5 10 14 25 23 2 4 27 24 3 28 30 19 33 29 31 18 32 34 21 36 26 37 38 35
2	11 16 1 6 17 12 14 10 3 24 20 22 25 13 19 18 7 8 4 2 26 29 23 15 9 5 33 21 30 28 31 35 34 32 37 36 27 38
3	2 4 1 15 8 7 3 19 5 18 23 20 21 26 25 6 27 28 12 17 30 22 11 16 9 13 10 14 33 34 24 29 36 35 37 31 32 38
4	8 7 13 9 18 5 10 14 4 2 16 11 24 22 25 19 15 23 3 28 12 17 26 31 6 1 32 29 20 21 34 27 33 35 30 36 37 38
5	16 11 7 8 17 12 4 2 1 18 14 15 20 22 19 27 21 25 9 24 3 13 6 30 31 26 28 32 33 10 34 23 29 36 5 35 37 38
6	6 5 18 1 19 3 11 16 14 10 22 24 17 12 8 7 15 25 23 29 13 21 2 4 31 9 33 27 20 28 35 32 26 36 34 30 38 37
7	5 6 10 14 12 15 17 23 22 3 19 18 9 7 27 8 25 26 20 28 29 24 30 21 4 2 11 16 13 1 35 34 31 33 36 32 38 37
8	5 6 2 4 21 9 14 10 15 3 24 25 22 19 7 8 11 16 13 23 12 26 30 29 28 20 1 18 27 33 34 17 36 35 31 32 38 37
9	15 1 3 19 5 13 9 6 18 24 10 14 16 11 2 4 17 12 7 8 30 20 23 27 28 31 29 21 22 26 25 33 36 35 34 37 38 32
10	2 4 10 14 6 21 17 12 13 5 18 1 7 8 23 26 15 22 11 16 25 9 19 3 27 20 32 29 24 30 35 31 36 34 28 33 37 38

### 10.1.5 Resultados del experimento E1-5

#### Árboles de corte: valores medios tras 10 ejecuciones

Coste flujo materiales medio:	1202,56
Coste flujo materiales máximo:	1286,28
Coste flujo materiales mínimo:	1140,26
Coste geométrico medio:	0
Coste geométrico máximo:	0
Coste geométrico mínimo:	0
Generación del óptimo media:	1739,7

#### Resultados de cada ejecución

Ejecución	Generación	Coste total	Coste mater.	Coste geom.
1	2576	1143,24	1143,24	0
2	1893	1275,82	1275,82	0
3	743	1223,15	1223,15	0
4	1113	1140,26	1140,26	0
5	1747	1211,78	1211,78	0
6	828	1184,86	1184,86	0
7	2471	1179,6	1179,6	0
8	725	1219,87	1219,87	0
9	2763	1160,73	1160,73	0
10	2538	1286,28	1286,28	0

#### Codificación del mejor árbol localizado en cada ejecución

Ejecución	Codificación del mejor árbol de la ejecución
1	14 10 3 21 11 16 18 6 1 15 5 13 9 26 7 8 20 28 12 17 4 2 19 31 24 29 33 32 23 30 22 34 36 27 25 37 35 38
2	18 20 3 19 1 5 12 10 6 9 22 24 14 13 4 2 21 25 8 7 15 23 16 11 30 28 31 27 33 29 17 32 35 26 37 34 38 36
3	11 16 9 5 20 18 7 8 10 14 24 23 12 17 4 2 1 15 6 13 19 3 28 30 22 26 29 25 34 31 21 27 32 33 37 35 36 38
4	1 5 8 7 20 22 11 16 14 10 18 6 9 13 19 3 23 26 2 4 12 17 21 15 31 24 30 29 33 32 27 25 28 34 35 36 37 38
5	4 2 7 8 14 15 22 6 5 9 12 10 19 21 23 26 25 18 20 24 27 3 29 30 13 1 31 32 17 28 11 16 35 34 36 33 37 38
6	2 4 5 13 6 21 9 22 10 14 3 19 18 1 23 26 27 24 17 12 25 29 8 7 20 32 16 11 15 30 28 33 34 35 36 31 38 37
7	8 7 4 2 9 5 18 1 16 11 12 17 20 21 19 3 23 13 27 6 14 10 29 31 30 22 28 33 32 25 34 35 15 24 37 26 38 36
8	11 16 14 10 15 22 9 7 2 4 3 1 6 5 17 12 26 18 24 8 28 21 13 23 19 25 33 29 31 32 20 30 27 36 34 37 35 38
9	2 4 7 8 19 21 17 12 15 24 6 5 3 26 1 13 20 22 23 27 10 14 9 31 16 11 18 29 34 30 28 33 35 32 25 37 36 38
10	10 12 16 11 17 20 5 15 3 14 18 19 8 7 9 6 25 21 1 13 27 23 30 24 4 2 26 33 32 29 31 28 36 34 35 37 22 38



## 10.1.6 Resultados del experimento E1-6

### Árboles de corte: valores medios tras 10 ejecuciones

Coste flujo materiales medio:	1201,74
Coste flujo materiales máximo:	1377,54
Coste flujo materiales mínimo:	1153,91
Coste geométrico medio:	0
Coste geométrico máximo:	0
Coste geométrico mínimo:	0
Generación del óptimo media:	2018,8

### Resultados de cada ejecución

Ejecución	Generación	Coste total	Coste mater.	Coste geom.
1	2532	1158,5	1158,5	0
2	300	1222,62	1222,62	0
3	2952	1377,54	1377,54	0
4	1436	1176,31	1176,31	0
5	2898	1153,91	1153,91	0
6	1730	1171,7	1171,7	0
7	2814	1166,46	1166,46	0
8	2993	1231,6	1231,6	0
9	1312	1158,01	1158,01	0
10	1221	1200,79	1200,79	0

### Codificación del mejor árbol localizado en cada ejecución

Ejecución	Codificación del mejor árbol de la ejecución
1	17 12 10 14 4 2 6 5 8 7 23 19 20 25 15 1 13 9 26 3 28 29 22 31 32 30 24 27 18 34 21 33 16 11 37 36 38 35
2	1 13 2 4 7 8 3 19 15 14 9 5 18 24 6 26 10 12 20 23 27 30 25 29 22 28 32 17 21 34 33 31 35 36 16 11 38 37
3	15 5 7 8 4 2 21 6 13 9 1 18 16 11 10 12 22 17 23 19 25 14 28 31 20 26 27 33 3 24 30 29 36 32 35 37 38 34
4	12 17 2 4 19 3 22 9 1 15 24 23 7 8 18 13 11 16 5 6 29 21 14 10 27 20 33 30 28 25 35 32 34 26 36 37 31 38
5	16 11 7 8 12 17 19 3 9 13 10 14 15 26 1 5 23 27 20 22 25 21 4 2 18 28 30 32 24 29 33 6 31 35 36 34 38 37
6	3 19 17 12 7 8 23 20 1 13 4 2 9 6 21 26 5 15 16 11 14 10 22 27 31 29 30 25 24 18 35 28 33 34 32 36 37 38
7	7 8 11 16 3 19 5 1 15 13 24 22 14 25 12 17 27 10 20 21 2 4 9 6 29 28 18 32 31 30 33 23 36 26 35 34 37 38
8	8 7 15 1 9 5 6 18 4 2 23 21 26 20 22 27 11 16 19 25 12 17 10 14 13 24 30 3 33 34 28 32 35 36 29 31 38 37
9	2 4 1 3 8 7 11 16 14 10 20 23 9 5 13 15 6 18 17 12 22 19 30 24 25 28 29 26 27 33 34 21 35 32 31 37 38 36
10	17 12 1 20 8 7 18 5 22 23 3 19 13 9 4 2 10 14 28 26 29 27 25 6 15 24 16 11 21 34 31 30 35 33 37 36 38 32

### 10.1.7 Resultados del experimento E1-7

#### Árboles de corte: valores medios tras 10 ejecuciones

Coste flujo materiales medio:	1231,79
Coste flujo materiales máximo:	1335,86
Coste flujo materiales mínimo:	1156,61
Coste geométrico medio:	0
Coste geométrico máximo:	0
Coste geométrico mínimo:	0
Generación del óptimo media:	2005,7

#### Resultados de cada ejecución

Ejecución	Generación	Coste total	Coste mater.	Coste geom.
1	1350	1174,16	1174,16	0
2	2978	1169,49	1169,49	0
3	2215	1305,94	1305,94	0
4	398	1251,87	1251,87	0
5	2504	1156,61	1156,61	0
6	3174	1184,5	1184,5	0
7	2765	1285,97	1285,97	0
8	1707	1249,75	1249,75	0
9	621	1203,74	1203,74	0
10	2345	1335,86	1335,86	0

#### Codificación del mejor árbol localizado en cada ejecución

Ejecución	Codificación del mejor árbol de la ejecución
1	18 1 5 15 7 8 9 13 14 10 19 3 24 25 11 16 27 22 12 17 29 26 21 6 28 30 4 2 23 20 33 32 35 34 31 37 36 38
2	4 2 17 12 15 13 9 21 8 7 20 25 6 5 19 3 27 26 24 29 18 1 28 22 14 23 10 33 11 16 30 31 32 34 36 37 38 35
3	11 15 6 5 14 10 22 3 7 8 24 19 9 13 27 23 25 1 2 4 20 29 12 21 18 31 16 17 32 34 33 30 26 36 35 28 38 37
4	5 1 12 17 6 18 19 3 10 14 4 2 21 23 20 25 11 16 8 7 22 15 13 9 32 29 31 33 30 28 27 34 35 36 24 26 38 37
5	10 14 8 7 3 21 16 11 4 2 20 22 5 1 27 13 17 12 19 25 6 9 31 18 15 28 23 33 29 24 32 26 30 36 37 35 34 38
6	10 14 2 4 8 7 1 5 9 22 12 17 19 3 16 11 24 6 13 18 15 26 20 23 21 27 31 28 32 29 33 34 25 35 30 37 38 36
7	3 19 6 5 8 7 2 4 13 9 18 22 26 15 11 1 17 12 20 23 27 29 10 14 31 28 30 24 32 25 21 34 16 35 33 36 38 37
8	8 7 10 14 20 21 11 16 6 5 25 13 1 18 27 3 2 4 19 29 15 22 26 9 28 31 24 32 12 30 17 23 33 34 37 36 38 35
9	3 19 9 13 2 4 6 5 18 20 10 14 17 12 1 15 27 28 7 8 26 21 11 16 25 30 22 32 23 24 34 29 35 33 36 31 37 38
10	6 7 4 2 9 21 10 14 19 22 11 16 5 8 1 13 24 15 23 26 25 3 27 20 29 12 18 32 31 28 17 30 36 33 37 34 35 38

## 10.2. RESULTADOS DE LOS EXPERIMENTOS DE PARAMETRIZACIÓN (E2)

### 10.2.1 Resultados del experimento E2-1

#### Valores medios máximos y mínimos obtenidos en el experimento

Coste mínimo del flujo de materiales de entre las distribuciones con mayor número de actividades geoméricamente válidas / Actividades válidas	8237,5 / 20
Coste flujo materiales medio:	8283,8
Coste flujo materiales máximo:	9411,1
Coste flujo materiales mínimo:	7321,9
Coste geométrico medio:	1,02
Coste geométrico máximo:	1,26
Coste geométrico mínimo:	0,95
Nº medio de actividades geoméricamente válidas:	18,9
Nº máximo de actividades geoméricamente válidas :	20
Nº mínimo de actividades geoméricamente válidas :	16
Generación del óptimo media:	1064,1

#### Detalle de las diferentes ejecuciones

Mejor distribución obtenida en cada ejecución <sup>61</sup>								
(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)
1	1489	18	1916,08	846,82	1069,26	0,66666	8468,20	1,07
2	1203	20	1776,13	823,75	952,38	0,66666	8237,50	0,95
3	1345	20	1798,35	845,96	952,39	0,66666	8459,60	0,95
4	353	19	1789,24	784,69	1004,55	0,66666	7846,90	1,00
5	850	19	1841,53	836,98	1004,55	0,66666	8369,80	1,00
6	1311	18	2024,5	941,11	1083,39	0,66666	9411,10	1,08
7	1512	19	1793,43	788,88	1004,55	0,66666	7888,80	1,00
8	87	16	1989,41	732,19	1257,22	0,66666	7321,90	1,26
9	1498	20	1797,85	845,47	952,38	0,66666	8454,70	0,95
10	993	20	1790,36	837,98	952,38	0,66666	8379,80	0,95

Codificación de la mejor distribución de cada ejecución	
Ejecución	Código
1	biidbddadbaiddabbd
2	bbiidaaiibabdaia d bi
3	abdddaaiiibabibdad bi
4	aaaddbiiidabbibda i
5	bbbddaiiddibabiaib d
6	bbddiibddibbada d b d
7	bbbiaaiiiddbabiad bi
8	abbbaabibidibdiad i
9	aaidibddda b a d a d b i a d
10	aadddbiddabadaibia d

<sup>61</sup> LEYENDA: (1) Ejecución, (2) Generación de la mejor distribución, (3) Número de actividades que cumplen sus restricciones geométricas, (4) Resultado de la función objetivo, (5) Coste del flujo de materiales ponderado, (6) Coste geométrico ponderado, (7) Ratio de la planta, (8) Coste del flujo de materiales, (9) Coste geométrico.

## 10.2.2 Resultados del experimento E2-2

### Valores medios máximos y mínimos obtenidos en el experimento

Coste mínimo del flujo de materiales de entre las distribuciones con mayor número de actividades geoméricamente válidas / Actividades válidas	8299,40 / 20
Coste flujo materiales medio:	8422,1
Coste flujo materiales máximo:	9565,6
Coste flujo materiales mínimo:	7622,8
Coste geométrico medio:	1,34
Coste geométrico máximo:	2,09
Coste geométrico mínimo:	0,95
Nº medio de actividades geoméricamente válidas:	16,9
Nº máximo de actividades geoméricamente válidas :	20
Nº mínimo de actividades geoméricamente válidas :	12
Generación del óptimo media:	1146,6

### Detalle de las diferentes ejecuciones

Mejor distribución obtenida en cada ejecución <sup>62</sup>								
(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)
1	474	20	1855,68	903,3	952,38	0,66666	9033,00	0,95
2	1423	18	1944,47	825,27	1119,2	0,66666	8252,70	1,12
3	1453	17	1944,6	762,28	1182,32	0,66666	7622,80	1,18
4	971	18	1908,44	839,18	1069,26	0,66666	8391,80	1,07
5	1294	12	2890,33	799,45	2090,88	0,66666	7994,50	2,09
6	1001	20	1864,88	912,5	952,38	0,66666	9125,00	0,95
7	1372	20	1908,94	956,56	952,38	0,66666	9565,60	0,95
8	1209	12	2867,98	803,16	2064,82	0,66666	8031,60	2,06
9	1324	12	2855,29	790,47	2064,82	0,66666	7904,70	2,06
10	945	20	1782,32	829,94	952,38	0,66666	8299,40	0,95

Codificación de la mejor distribución de cada ejecución	
Ejecución	Código
1	a b i d d a i d i b b b i b d a d b i
2	a b b d a a d d d d i i b d d b a a d
3	b i d b b d a a a a b i d i i a b i d
4	b d i i b i i a i a b d i d i b a a i
5	b a b b b b i b d d d i b i i d d b
6	b a i d i b d d d a b b i a d b i a d
7	b b d i i b i d i b a a i b d b d b i
8	b a d a b b a i b i a i d a d d i i b
9	b b i a b a a i a i b i d b i d i i a
10	a a d d i b d d d a b a d a d b i a d

<sup>62</sup> LEYENDA: (1) Ejecución, (2) Generación de la mejor distribución, (3) Número de actividades que cumplen sus restricciones geométricas, (4) Resultado de la función objetivo, (5) Coste del flujo de materiales ponderado, (6) Coste geométrico ponderado, (7) Ratio de la planta, (8) Coste del flujo de materiales, (9) Coste geométrico.

## 10.2.3 Resultados del experimento E2-3

### Valores medios máximos y mínimos obtenidos en el experimento

Coste mínimo del flujo de materiales de entre las distribuciones con mayor número de actividades geoméricamente válidas / Actividades válidas	8365,20 / 20
Coste flujo materiales medio:	8593,22
Coste flujo materiales máximo:	10451,10
Coste flujo materiales mínimo:	7475,9
Coste geométrico medio:	1,50
Coste geométrico máximo:	2,74
Coste geométrico mínimo:	0,95
Nº medio de actividades geoméricamente válidas:	15,8
Nº máximo de actividades geoméricamente válidas :	20
Nº mínimo de actividades geoméricamente válidas :	10
Generación del óptimo media:	899,2

### Detalle de las diferentes ejecuciones

Mejor distribución obtenida en cada ejecución <sup>63</sup>								
(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)
1	743	11	3336,72	947,96	2388,76	0,66666	9479,60	2,39
2	1148	10	3585,95	849,98	2735,97	0,66666	8499,80	2,74
3	1309	18	1941,38	822,17	1119,21	0,66666	8221,70	1,12
4	1084	16	2004,81	747,59	1257,22	0,66666	7475,90	1,26
5	939	17	2227,44	1045,11	1182,33	0,66666	10451,10	1,18
6	1068	20	1815,97	863,59	952,38	0,66666	8635,90	0,95
7	403	17	1963,98	781,66	1182,32	0,66666	7816,60	1,18
8	768	17	1961,37	779,05	1182,32	0,66666	7790,50	1,18
9	1485	12	2863,95	799,13	2064,82	0,66666	7991,30	2,06
10	45	20	1909,36	956,98	952,38	0,66666	9569,80	0,95

Codificación de la mejor distribución de cada ejecución	
Ejecución	Código
1	b i b b b d a b a i i i d i d d d i a
2	a d a a d i a d a d d d i i i i b d a
3	a b b d b a d d d d i i a i d a b b d
4	b d b a a i a b b i d d b d i b a d i
5	b a d a b b b d a a a i d i d a a d i
6	b b d d i a i d d b b b d b i a i b d
7	b i d a b d a a a a b i i i d a b i d
8	a d d b b i a a a a b d i d d a b d i
9	b b d a a a b i b i b i d b i d i i a
10	b b d d d b i d d b a b d a i a i a d

<sup>63</sup> LEYENDA: (1) Ejecución, (2) Generación de la mejor distribución, (3) Número de actividades que cumplen sus restricciones geométricas, (4) Resultado de la función objetivo, (5) Coste del flujo de materiales ponderado, (6) Coste geométrico ponderado, (7) Ratio de la planta, (8) Coste del flujo de materiales, (9) Coste geométrico.

## 10.2.4 Resultados del experimento E2-4

### Valores medios máximos y mínimos obtenidos en el experimento

Coste mínimo del flujo de materiales de entre las distribuciones con mayor número de actividades geoméricamente válidas / Actividades válidas	8597,70 / 20
Coste flujo materiales medio:	9308,9
Coste flujo materiales máximo:	11479,60
Coste flujo materiales mínimo:	8330,4
Coste geométrico medio:	1
Coste geométrico máximo:	1,26
Coste geométrico mínimo:	0,95
Nº medio de actividades geoméricamente válidas:	19,2
Nº máximo de actividades geoméricamente válidas :	20
Nº mínimo de actividades geoméricamente válidas :	17
Generación del óptimo media:	849,1

### Detalle de las diferentes ejecuciones

Mejor distribución obtenida en cada ejecución <sup>64</sup>								
(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)
1	598	16	2405,18	1147,96	1257,22	0,66666	11479,60	1,26
2	372	20	1887,54	935,16	952,38	0,66666	9351,60	0,95
3	356	20	1845,49	893,11	952,38	0,66666	8931,10	0,95
4	1440	20	1935,03	982,64	952,39	0,66666	9826,40	0,95
5	1416	18	1902,3	833,04	1069,26	0,66666	8330,40	1,07
6	1388	20	1812,15	859,77	952,38	0,66666	8597,70	0,95
7	760	19	1937,47	912,8	1024,67	0,66666	9128,00	1,02
8	1236	19	1894,88	890,33	1004,55	0,66666	8903,30	1,00
9	629	20	1840,51	888,13	952,38	0,66666	8881,30	0,95
10	296	20	1918,34	965,96	952,38	0,66666	9659,60	0,95

Codificación de la mejor distribución de cada ejecución	
Ejecución	Código
1	a d a a b d b a a d d i a d i b b d d
2	a a i i d b d d d a a a i a d a i b d
3	b a d d d b d d d b a b d b i b i a d
4	b b i i i a d i d a b a i b d a d b i
5	b i d d b d i a d b a i d i i a b b d
6	a b d d d a d i d b a b i a d a i b d
7	b i i d d d i b i b b b d a i a d b i
8	b a b d i b d d i d i a a a d a i b d
9	a b d d i a d d d a a b d b d b i a d
10	b a i i i a i d d b b a d b d b i a d

<sup>64</sup> LEYENDA: (1) Ejecución, (2) Generación de la mejor distribución, (3) Número de actividades que cumplen sus restricciones geométricas, (4) Resultado de la función objetivo, (5) Coste del flujo de materiales ponderado, (6) Coste geométrico ponderado, (7) Ratio de la planta, (8) Coste del flujo de materiales, (9) Coste geométrico.

## 10.2.5 Resultados del experimento E2-5

### Valores medios máximos y mínimos obtenidos en el experimento

Coste mínimo del flujo de materiales de entre las distribuciones con mayor número de actividades geoméricamente válidas / Actividades válidas	8103,70 / 20
Coste flujo materiales medio:	7810,1
Coste flujo materiales máximo:	8228,6
Coste flujo materiales mínimo:	7076,3
Coste geométrico medio:	1,09
Coste geométrico máximo:	1,26
Coste geométrico mínimo:	0,95
Nº medio de actividades geoméricamente válidas:	18,1
Nº máximo de actividades geoméricamente válidas :	20
Nº mínimo de actividades geoméricamente válidas :	16
Generación del óptimo media:	633,8

### Detalle de las diferentes ejecuciones

Mejor distribución obtenida en cada ejecución <sup>65</sup>								
(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)
1	1477	16	1964,85	707,63	1257,22	0,66666	7076,30	1,26
2	598	17	1944,6	762,28	1182,32	0,66666	7622,80	1,18
3	356	20	1762,75	810,37	952,38	0,66666	8103,70	0,95
4	926	18	1892,12	822,86	1069,26	0,66666	8228,60	1,07
5	810	20	1762,75	810,37	952,38	0,66666	8103,70	0,95
6	549	20	1762,75	810,37	952,38	0,66666	8103,70	0,95
7	514	17	1917,02	783,3	1133,72	0,66666	7833,00	1,13
8	400	16	1978,06	720,84	1257,22	0,66666	7208,40	1,26
9	474	18	1928,07	808,87	1119,2	0,66666	8088,70	1,12
10	234	19	1777,77	773,22	1004,55	0,66666	7732,20	1,00

Codificación de la mejor distribución de cada ejecución	
Ejecución	Código
1	biabbd a a a d i i a i d a b i d
2	a i d a a d b b b b a i d i i b a i d
3	b b d d i a d d d b a b d a i a i b d
4	b i d d b d d a d b a i d i i a b b d
5	b b d d i a d d d b a b d a i a i b d
6	a a d d i b d d d a b a d b i b i a d
7	b d b i b i i a i d d a d i a b b i
8	b a a b b b a d a i d d a d i a b d i
9	b a b i b b i i i d d a d i a b b i
10	a a a i d b i i i d a b b i b d a i

<sup>65</sup> LEYENDA: (1) Ejecución, (2) Generación de la mejor distribución, (3) Número de actividades que cumplen sus restricciones geométricas, (4) Resultado de la función objetivo, (5) Coste del flujo de materiales ponderado, (6) Coste geométrico ponderado, (7) Ratio de la planta, (8) Coste del flujo de materiales, (9) Coste geométrico.

## 10.2.6 Resultados del experimento E2-6

### Valores medios máximos y mínimos obtenidos en el experimento

Coste mínimo del flujo de materiales de entre las distribuciones con mayor número de actividades geoméricamente válidas / Actividades válidas	8103,70 / 20
Coste flujo materiales medio:	8003,9
Coste flujo materiales máximo:	8228,6
Coste flujo materiales mínimo:	7622,8
Coste geométrico medio:	1,01
Coste geométrico máximo:	1,18
Coste geométrico mínimo:	0,95
Nº medio de actividades geoméricamente válidas:	19,1
Nº máximo de actividades geoméricamente válidas :	20
Nº mínimo de actividades geoméricamente válidas :	17
Generación del óptimo media:	330,5

### Detalle de las diferentes ejecuciones

Mejor distribución obtenida en cada ejecución <sup>66</sup>								
(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)
1	115	18	1892,12	822,86	1069,26	0,66666	8228,60	1,07
2	173	20	1762,75	810,37	952,38	0,66666	8103,70	0,95
3	257	17	1944,6	762,28	1182,32	0,66666	7622,80	1,18
4	606	20	1762,75	810,37	952,38	0,66666	8103,70	0,95
5	340	20	1762,75	810,37	952,38	0,66666	8103,70	0,95
6	620	20	1762,75	810,37	952,38	0,66666	8103,70	0,95
7	202	17	1917,02	783,3	1133,72	0,66666	7833,00	1,13
8	162	19	1777,77	773,22	1004,55	0,66666	7732,20	1,00
9	739	20	1762,75	810,37	952,38	0,66666	8103,70	0,95
10	91	20	1762,75	810,37	952,38	0,66666	8103,70	0,95

Codificación de la mejor distribución de cada ejecución	
Ejecución	Código
1	bdiibiaibadiddabbi
2	bbddiadddbabdaiaibd
3	bidbbdaaaabidiiabid
4	aaiddbiiiabaibdbdai
5	aaddibdddabdbibia d
6	aaiddbiiiabaibdbdai
7	bibdbddaddiiaidabbd
8	aaadibdddiaabdbiad
9	aaiddbiiiabaibdbdai
10	bbddiadddbabdaiaibd

<sup>66</sup> LEYENDA: (1) Ejecución, (2) Generación de la mejor distribución, (3) Número de actividades que cumplen sus restricciones geométricas, (4) Resultado de la función objetivo, (5) Coste del flujo de materiales ponderado, (6) Coste geométrico ponderado, (7) Ratio de la planta, (8) Coste del flujo de materiales, (9) Coste geométrico.



## 10.2.7 Resultados del experimento E2-7

### Valores medios máximos y mínimos obtenidos en el experimento

Coste mínimo del flujo de materiales de entre las distribuciones con mayor número de actividades geoméricamente válidas / Actividades válidas	8103,70 / 20
Coste flujo materiales medio:	8024,7
Coste flujo materiales máximo:	8420,5
Coste flujo materiales mínimo:	7673,8
Coste geométrico medio:	1,2
Coste geométrico máximo:	2,06
Coste geométrico mínimo:	0,95
Nº medio de actividades geoméricamente válidas:	18
Nº máximo de actividades geoméricamente válidas :	20
Nº mínimo de actividades geoméricamente válidas :	12
Generación del óptimo media:	599

### Detalle de las diferentes ejecuciones

Mejor distribución obtenida en cada ejecución <sup>67</sup>								
(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)
1	1305	19	1866,72	842,05	1024,67	0,66666	8420,50	1,02
2	1300	19	1777,77	773,22	1004,55	0,66666	7732,20	1,00
3	105	18	1892,12	822,86	1069,26	0,66666	8228,60	1,07
4	1400	20	1762,75	810,37	952,38	0,66666	8103,70	0,95
5	100	20	1762,75	810,37	952,38	0,66666	8103,70	0,95
6	900	20	1762,75	810,37	952,38	0,66666	8103,70	0,95
7	99	20	1762,75	810,37	952,38	0,66666	8103,70	0,95
8	200	12	2832,2	767,38	2064,82	0,66666	7673,80	2,06
9	400	20	1762,75	810,37	952,38	0,66666	8103,70	0,95
10	181	12	2832,2	767,38	2064,82	0,66666	7673,80	2,06

Codificación de la mejor distribución de cada ejecución	
Ejecución	Código
1	a d i i i d a i a b a i b d b d a i
2	a a a i d b i i i d a b b i b d a i
3	b i d d b d d a d b a i d i i a b b d
4	a a d d i b d d d a b a d b i b i a d
5	b b d d i a d d d b a b d a i a i b d
6	a a i i d b i i i a b a i b d b d a i
7	a a d d i b d d d a b a d b i b i a d
8	a b i a a a a i a i b d a i d i i a
9	a a d d i b d d d a b a d b i b i a d
10	b a d b b b b d b d a d i b d i d d b

<sup>67</sup> LEYENDA: (1) Ejecución, (2) Generación de la mejor distribución, (3) Número de actividades que cumplen sus restricciones geométricas, (4) Resultado de la función objetivo, (5) Coste del flujo de materiales ponderado, (6) Coste geométrico ponderado, (7) Ratio de la planta, (8) Coste del flujo de materiales, (9) Coste geométrico.

## 10.2.8 Resultados del experimento E2-8

### Valores medios máximos y mínimos obtenidos en el experimento

Coste mínimo del flujo de materiales de entre las distribuciones con mayor número de actividades geoméricamente válidas / Actividades válidas	8103,70 / 20
Coste flujo materiales medio:	8129
Coste flujo materiales máximo:	8416
Coste flujo materiales mínimo:	7732,2
Coste geométrico medio:	0,97
Coste geométrico máximo:	1,02
Coste geométrico mínimo:	0,95
Nº medio de actividades geoméricamente válidas:	19,7
Nº máximo de actividades geoméricamente válidas :	20
Nº mínimo de actividades geoméricamente válidas :	19
Generación del óptimo media:	856,5

### Detalle de las diferentes ejecuciones

Mejor distribución obtenida en cada ejecución <sup>68</sup>								
(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)
1	1199	20	1762,75	810,37	952,38	0,66666	8103,70	0,95
2	300	19	1859,82	841,6	1018,22	0,66666	8416,00	1,02
3	1500	19	1774,99	773,22	1001,77	0,66666	7732,20	1,00
4	1300	20	1762,75	810,37	952,38	0,66666	8103,70	0,95
5	1100	20	1762,75	810,37	952,38	0,66666	8103,70	0,95
6	900	20	1762,75	810,37	952,38	0,66666	8103,70	0,95
7	300	20	1762,75	810,37	952,38	0,66666	8103,70	0,95
8	1000	20	1762,75	810,37	952,38	0,66666	8103,70	0,95
9	900	20	1762,75	810,37	952,38	0,66666	8103,70	0,95
10	66	19	1859,82	841,6	1018,22	0,66666	8416,00	1,02

Codificación de la mejor distribución de cada ejecución	
Ejecución	Código
1	a a d d i b d d d a b a d b i b i a d
2	b b d d a a d d d b a i d i i a b b d
3	b b b d i a d d d d i b a a d a i b d
4	a a d d i b d d d a b a d b i b i a d
5	b b d d i a d d d b a b d a i a i b d
6	a a d d i b d d d a b a d b i b i a d
7	b b i i d a i i b a b i a d a d b i
8	a a d d i b d d d a b a d b i b i a d
9	a a i i d b i i i a b a i b d b d a i
10	b b i i a a i i b a d i d d a b b i

<sup>68</sup> LEYENDA: (1) Ejecución, (2) Generación de la mejor distribución, (3) Número de actividades que cumplen sus restricciones geométricas, (4) Resultado de la función objetivo, (5) Coste del flujo de materiales ponderado, (6) Coste geométrico ponderado, (7) Ratio de la planta, (8) Coste del flujo de materiales, (9) Coste geométrico.

## 10.2.9 Resultados del experimento E2-9

### Valores medios máximos y mínimos obtenidos en el experimento

Coste mínimo del flujo de materiales de entre las distribuciones con mayor número de actividades geoméricamente válidas / Actividades válidas	8103,70 / 20
Coste flujo materiales medio:	8091,9
Coste flujo materiales máximo:	8416
Coste flujo materiales mínimo:	7673,8
Coste geométrico medio:	1,03
Coste geométrico máximo:	1,69
Coste geométrico mínimo:	0,95
Nº medio de actividades geoméricamente válidas:	19,1
Nº máximo de actividades geoméricamente válidas :	20
Nº mínimo de actividades geoméricamente válidas :	12
Generación del óptimo media:	381,1

### Detalle de las diferentes ejecuciones

Mejor distribución obtenida en cada ejecución <sup>69</sup>								
(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)
1	456	20	1762,75	810,37	952,38	0,66666	8103,70	0,95
2	200	20	1762,75	810,37	952,38	0,66666	8103,70	0,95
3	654	20	1762,75	810,37	952,38	0,66666	8103,70	0,95
4	345	19	1859,82	841,6	1018,22	0,66666	8416,00	1,02
5	500	20	1762,75	810,37	952,38	0,66666	8103,70	0,95
6	345	20	1762,75	810,37	952,38	0,66666	8103,70	0,95
7	432	20	1762,75	810,37	952,38	0,66666	8103,70	0,95
8	145	12	2461,99	767,38	1694,61	0,66666	7673,80	1,69
9	500	20	1762,75	810,37	952,38	0,66666	8103,70	0,95
10	234	20	1762,75	810,37	952,38	0,66666	8103,70	0,95

Codificación de la mejor distribución de cada ejecución	
Ejecución	Código
1	bbddiadddbabdaiaibd
2	bbidaaiibabiadadbi
3	aaddibdddabadbibiad
4	bbddaadddbaidiabbd
5	aaddibdddabadbibiad
6	bbddiadddbabdaiaibd
7	bbddiadddbabdaiaibd
8	abiaaaaiaibidaidia
9	bbidaaiibabiadadbi
10	aaiidbiiabaibdbdai

<sup>69</sup> LEYENDA: (1) Ejecución, (2) Generación de la mejor distribución, (3) Número de actividades que cumplen sus restricciones geométricas, (4) Resultado de la función objetivo, (5) Coste del flujo de materiales ponderado, (6) Coste geométrico ponderado, (7) Ratio de la planta, (8) Coste del flujo de materiales, (9) Coste geométrico.

## 10.2.10 Resultados del experimento E2-10

### Valores medios máximos y mínimos obtenidos en el experimento

Coste mínimo del flujo de materiales de entre las distribuciones con mayor número de actividades geoméricamente válidas / Actividades válidas	7732,15 / 19
Coste flujo materiales medio:	7404,22
Coste flujo materiales máximo:	7732,15
Coste flujo materiales mínimo:	7076,29
Coste geométrico medio:	1,13
Coste geométrico máximo:	1,26
Coste geométrico mínimo:	1,00
Nº medio de actividades geoméricamente válidas:	17,5
Nº máximo de actividades geoméricamente válidas :	19
Nº mínimo de actividades geoméricamente válidas :	16
Generación del óptimo media:	277

### Detalle de las diferentes ejecuciones

Mejor distribución obtenida en cada ejecución <sup>70</sup>								
(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)
1	100	16	1964,859	707,629	1257,23	0,66666	7076,29	1,26
2	300	16	1964,859	707,629	1257,23	0,66666	7076,29	1,26
3	175	16	1964,859	707,629	1257,23	0,66666	7076,29	1,26
4	100	19	1777,765	773,215	1004,55	0,66666	7732,15	1,00
5	1000	16	1964,859	707,629	1257,23	0,66666	7076,29	1,26
6	307	19	1777,765	773,215	1004,55	0,66666	7732,15	1,00
7	164	19	1777,765	773,215	1004,55	0,66666	7732,15	1,00
8	200	19	1777,765	773,215	1004,55	0,66666	7732,15	1,00
9	327	19	1777,765	773,215	1004,55	0,66666	7732,15	1,00
10	97	16	1964,859	707,629	1257,23	0,66666	7076,29	1,26

Codificación de la mejor distribución de cada ejecución	
Ejecución	Código
1	b d a b b i a a a i d d a d i a b d i
2	a i b a a d b b b d i i b i d b a i d
3	a d b a a i b b b i d d b d i b a d i
4	b b b i d a i i i d b a a i a d b i
5	a d b a a i b b b i d d b d i b a d i
6	a a a d i b d d d d i a b b d b i a d
7	b b b d i a d d d d i b a a d a i b d
8	a a a i d b i i i d a b b i b d a i
9	a a a d i b d d d d i a b b d b i a d
10	b d a b b i a a a i d d a d i a b d i

<sup>70</sup> LEYENDA: (1) Ejecución, (2) Generación de la mejor distribución, (3) Número de actividades que cumplen sus restricciones geométricas, (4) Resultado de la función objetivo, (5) Coste del flujo de materiales ponderado, (6) Coste geométrico ponderado, (7) Ratio de la planta, (8) Coste del flujo de materiales, (9) Coste geométrico.

## 10.2.11 Resultados del experimento E2-11

### Valores medios máximos y mínimos obtenidos en el experimento

Coste mínimo del flujo de materiales de entre las distribuciones con mayor número de actividades geoméricamente válidas / Actividades válidas	7331,39 / 15
Coste flujo materiales medio:	6928,922
Coste flujo materiales máximo:	7331,39
Coste flujo materiales mínimo:	6828,306
Coste geométrico medio:	1,84
Coste geométrico máximo:	2,08
Coste geométrico mínimo:	1,78
Nº medio de actividades geoméricamente válidas:	14,2
Nº máximo de actividades geoméricamente válidas :	15
Nº mínimo de actividades geoméricamente válidas :	14
Generación del óptimo media:	287,2

### Detalle de las diferentes ejecuciones

Mejor distribución obtenida en cada ejecución <sup>71</sup>								
(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)
1	1000	14	2461,351	682,831	1778,52	0,66666	6828,31	1,78
2	96	15	2816,189	733,139	2083,05	0,66666	7331,39	2,08
3	200	14	2461,351	682,831	1778,52	0,66666	6828,31	1,78
4	376	14	2461,351	682,831	1778,52	0,66666	6828,31	1,78
5	206	14	2461,351	682,831	1778,52	0,66666	6828,31	1,78
6	80	15	2816,189	733,139	2083,05	0,66666	7331,39	2,08
7	100	14	2461,351	682,831	1778,52	0,66666	6828,31	1,78
8	614	14	2461,351	682,831	1778,52	0,66666	6828,31	1,78
9	100	14	2461,351	682,831	1778,52	0,66666	6828,31	1,78
10	100	14	2461,351	682,831	1778,52	0,66666	6828,31	1,78

Codificación de la mejor distribución de cada ejecución	
Ejecución	Código
1	a i d a a d b b b d i i b i d b a i d
2	b b i i d a i i i d b a i a d b i
3	a d i a a i b b b i d d b d i b a d i
4	b i d b b d a a a d i i a i d a b i d
5	b d i b b i a a a i d d a d i a b d i
6	a a i i d b i i i d a b i i b d a i
7	a i d a a d b b b d i i b i d b a i d
8	b i d b b d a a a d i i a i d a b i d
9	a i d a a d b b b d i i b i d b a i d
10	b d i b b i a a a i d d a d i a b d i

<sup>71</sup> LEYENDA: (1) Ejecución, (2) Generación de la mejor distribución, (3) Número de actividades que cumplen sus restricciones geométricas, (4) Resultado de la función objetivo, (5) Coste del flujo de materiales ponderado, (6) Coste geométrico ponderado, (7) Ratio de la planta, (8) Coste del flujo de materiales, (9) Coste geométrico.

### 10.2.12 Resultados del experimento E2-12

#### Valores medios máximos y mínimos obtenidos en el experimento

Coste mínimo del flujo de materiales de entre las distribuciones con mayor número de actividades geoméricamente válidas / Actividades válidas	5653,02 / 8
Coste flujo materiales medio:	5122,673
Coste flujo materiales máximo:	5653,0205
Coste flujo materiales mínimo:	4734,563
Coste geométrico medio:	20,53
Coste geométrico máximo:	29,66
Coste geométrico mínimo:	13,35
Nº medio de actividades geoméricamente válidas:	6,2
Nº máximo de actividades geoméricamente válidas :	8
Nº mínimo de actividades geoméricamente válidas :	4
Generación del óptimo media:	409

#### Detalle de las diferentes ejecuciones

Mejor distribución obtenida en cada ejecución <sup>72</sup>								
(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)
1	100	8	13920,592	565,302	13355,29	0,666666	5653,02	13,36
2	100	8	13920,592	565,302	13355,29	0,666666	5653,02	13,36
3	1300	4	30139,276	473,456	29665,82	0,666666	4734,56	29,67
4	100	7	17083,6	483,82	16599,78	0,666666	4838,20	16,60
5	400	4	30139,276	473,456	29665,82	0,666666	4734,56	29,67
6	300	4	30139,276	473,456	29665,82	0,666666	4734,56	29,67
7	200	8	13920,592	565,302	13355,29	0,666666	5653,02	13,36
8	200	7	17083,6	483,82	16599,78	0,666666	4838,20	16,60
9	100	8	13920,592	565,302	13355,29	0,666666	5653,02	13,36
10	1290	4	30139,276	473,456	29665,82	0,666666	4734,56	29,67

Codificación de la mejor distribución de cada ejecución	
Ejecución	Código
1	idiibiiiaiddididbdi
2	diddadddiiddiaid
3	daddiadaddiiddiidd
4	aiaaadabaabiadabdba
5	iaiidaiiaiddididdi
6	daddiadaddiiddiidd
7	idiiaibiiddididadi
8	aiaaadabaabiadabdba
9	diddadddiiddiaid
10	daddiadaddiiddiidd

<sup>72</sup> LEYENDA: (1) Ejecución, (2) Generación de la mejor distribución, (3) Número de actividades que cumplen sus restricciones geométricas, (4) Resultado de la función objetivo, (5) Coste del flujo de materiales ponderado, (6) Coste geométrico ponderado, (7) Ratio de la planta, (8) Coste del flujo de materiales, (9) Coste geométrico.

### 10.2.13 Resultados del experimento E2-13

#### Valores medios máximos y mínimos obtenidos en el experimento

Coste mínimo del flujo de materiales de entre las distribuciones con mayor número de actividades geoméricamente válidas / Actividades válidas	4298,23 / 5
Coste flujo materiales medio:	4569,98
Coste flujo materiales máximo:	5270,42
Coste flujo materiales mínimo:	4298,23
Coste geométrico medio:	27,16
Coste geométrico máximo:	29,67
Coste geométrico mínimo:	24,78
Nº medio de actividades geoméricamente válidas:	4,5
Nº máximo de actividades geoméricamente válidas :	5
Nº mínimo de actividades geoméricamente válidas :	4
Generación del óptimo media:	363,9

#### Detalle de las diferentes ejecuciones

Mejor distribución obtenida en cada ejecución <sup>73</sup>								
(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)
1	241	4	266393,98	236728,16	29665,82	0,66666	4734,56	29,67
2	500	4	292548,54	263521,16	29027,38	0,66666	5270,42	29,03
3	806	5	239687,07	214911,62	24775,45	0,66666	4298,23	24,78
4	130	5	239687,07	214911,62	24775,45	0,66666	4298,23	24,78
5	796	5	239687,07	214911,62	24775,45	0,66666	4298,23	24,78
6	100	4	266393,98	236728,16	29665,82	0,66666	4734,56	29,67
7	100	4	266393,98	236728,16	29665,82	0,66666	4734,56	29,67
8	100	4	266393,98	236728,16	29665,82	0,66666	4734,56	29,67
9	566	5	239687,07	214911,62	24775,45	0,66666	4298,23	24,78
10	300	5	239687,07	214911,62	24775,45	0,66666	4298,23	24,78

Codificación de la mejor distribución de cada ejecución	
Ejecución	Código
1	dbddibdbddiiddiidd
2	bbiabaabaiddbibdibba
3	aiaaiaaabiababbba
4	adaaddadaabdababbba
5	bibbiibbbaibabaaab
6	daddiadaddiiddiidd
7	iaiidaiiiddididdi
8	ibiidbibiiddididdi
9	aiaaiaaabiababbba
10	adaaddadaabdababbba

<sup>73</sup> LEYENDA: (1) Ejecución, (2) Generación de la mejor distribución, (3) Número de actividades que cumplen sus restricciones geométricas, (4) Resultado de la función objetivo, (5) Coste del flujo de materiales ponderado, (6) Coste geométrico ponderado, (7) Ratio de la planta, (8) Coste del flujo de materiales, (9) Coste geométrico.

### 10.2.14 Resultados del experimento E2-14

#### Valores medios máximos y mínimos obtenidos en el experimento

Coste mínimo del flujo de materiales de entre las distribuciones con mayor número de actividades geoméricamente válidas / Actividades válidas	4298,23 / 5
Coste flujo materiales medio:	4359,72
Coste flujo materiales máximo:	5225,12
Coste flujo materiales mínimo:	2677,30
Coste geométrico medio:	46,71
Coste geométrico máximo:	204,64
Coste geométrico mínimo:	24,77
Nº medio de actividades geoméricamente válidas:	3,9
Nº máximo de actividades geoméricamente válidas :	5
Nº mínimo de actividades geoméricamente válidas :	0
Generación del óptimo media:	253,4

#### Detalle de las diferentes ejecuciones

Mejor distribución obtenida en cada ejecución <sup>74</sup>								
(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)
1	200	4	30139,27	473,45	29665,82	0,66666	4734,56	29,67
2	350	5	25205,26	429,82	24775,44	0,66666	4298,23	24,78
3	100	0	204908,71	267,73	204640,98	0,66666	2677,30	204,64
4	98	5	25205,26	429,82	24775,44	0,66666	4298,23	24,78
5	1030	5	25205,26	429,82	24775,44	0,66666	4298,23	24,78
6	268	2	50065,36	522,51	49542,85	0,66666	5225,12	49,54
7	188	5	25205,26	429,82	24775,44	0,66666	4298,23	24,78
8	100	5	25205,26	429,82	24775,44	0,66666	4298,23	24,78
9	100	4	30139,27	473,45	29665,82	0,66666	4734,56	29,67
10	100	4	30139,27	473,45	29665,82	0,66666	4734,56	29,67

Codificación de la mejor distribución de cada ejecución	
Ejecución	Código
1	d a d d i a d a d d i i d i d i i d
2	a d a a d d a d a a b d a b a b b b a
3	b a b b a b b a b b a a b a b a a a b
4	a i a a i i a i a a b i a b a b b b a
5	b i b b i i b i b b a i b a b a a a b
6	i d a i d i i d i b b d a d i d d d i
7	a i a a i i a i a a b i a b a b b b a
8	a d a a d d a d a a b d a b a b b b a
9	i b i i d b i b i d d i d i d d d i
10	d b d d i b d b d d i i d i d i i d

<sup>74</sup> LEYENDA: (1) Ejecución, (2) Generación de la mejor distribución, (3) Número de actividades que cumplen sus restricciones geométricas, (4) Resultado de la función objetivo, (5) Coste del flujo de materiales ponderado, (6) Coste geométrico ponderado, (7) Ratio de la planta, (8) Coste del flujo de materiales, (9) Coste geométrico.



### 10.3. RESULTADOS DEL EXPERIMENTO (E3)

#### 10.3.1 Resultados obtenidos en LG1

#### Árboles de corte: valores medios de los mejores árboles obtenidos en 10 ejecuciones

Coste flujo materiales medio: <sup>75</sup>	51,10
Coste flujo materiales máximo:	56,21
Coste flujo materiales mínimo:	46,81
Coste geométrico medio:	0
Coste geométrico máximo:	0
Coste geométrico mínimo:	0
Generación del óptimo media:	1897,6

#### Datos del mejor árbol localizado en cada ejecución

Ejecución	Generación	Coste total	Coste mater.	Coste geom.
1	489	52,66	52,66	0
2	521	51,12	51,12	0
3	1507	48,64	48,64	0
4	2564	53,98	53,98	0
5	1987	46,81	46,81	0
6	2004	56,21	56,21	0
7	1987	48,97	48,97	0
8	2543	49,29	49,29	0
9	2897	49,16	49,16	0
10	2531	52,53	52,53	0

#### Codificación del mejor árbol localizado en cada ejecución

Ejecución	Codificación
1	35 20 28 22 37 23 27 14 33 21 26 25 13 15 39 30 2 16 44 12 47 41 4 43 10 8 46 24 18 38 1 36 9 34 17 56 42 11 55 53 40 3 7 58 50 6 51 57 31 32 54 63 48 61 49 62 60 67 65 45 29 5 66 59 69 19 68 64 73 70 52 71 75 74 77 72 76 78
2	32 37 30 35 31 15 41 14 7 42 43 28 36 4 23 1 27 2 18 8 12 9 38 50 34 22 26 16 11 19 5 25 24 49 3 13 33 21 54 48 39 10 29 53 58 59 20 17 61 40 62 44 55 65 51 56 6 57 52 66 64 45 47 68 46 67 70 72 63 69 73 74 60 71 75 77 78 76
3	35 8 39 1 37 40 38 26 27 2 20 34 25 32 21 33 23 18 14 47 22 7 50 36 24 15 51 48 10 3 42 17 16 13 49 9 44 52 12 11 45 53 60 56 6 29 59 54 41 58 57 4 46 31 5 30 65 67 68 63 28 61 71 19 69 66 55 43 73 72 70 62 75 64 74 76 78 77
4	24 27 10 8 17 7 12 36 32 31 21 33 1 11 2 39 34 9 23 20 4 35 18 38 14 41 42 50 30 37 16 13 45 22 28 56 49 53 3 15 46 44 55 29 40 43 5 26 48 54 51 25 47 60 66 63 19 67 69 6 59 58 57 68 64 61 62 52 65 74 72 73 70 75 71 76 78 77
5	10 38 2 24 34 30 8 1 28 31 35 39 23 18 29 20 32 37 17 7 43 14 5 46 26 3 22 11 51 49 45 54 50 6 4 27 16 13 48 52 21 15 42 36 41 57 33 19 25 40 53 65 12 61 9 47 66 44 62 63 59 68 70 56 69 64 71 67 55 58 75 72 73 74 77 60 78 76
6	29 6 21 12 36 9 23 22 10 35 15 20 18 37 2 1 31 46 32 16 49 43 40 26 41 45 39 14 17 48 50 34 5 19 3 13 4 56 38 47 28 24 60 52 44 59 11 25 33 55 62 53 64 61 27 30 8 58 42 65 63 51 69 67 70 66 71 72 7 57 73 75 54 68 74 77 78 76
7	28 39 34 31 19 5 21 33 17 8 10 42 3 26 46 36 14 22 27 4 24 12 35 2 45 6 20 37 52 41 30 49 44 48 29 40 1 11 16 32 13 15 57 59 51 9 60 25 18 38 23 47 50 54 7 64 65 53 66 67 43 61 56 58 68 55 69 63 62 74 75 71 73 70 76 77 72 78
8	27 12 30 15 3 13 9 34 6 7 37 32 29 40 10 39 2 24 21 33 26 23 4 31 20 36 42 14 16 17 47 38 25 18 55 43 35 48 51 41 53 49 57 44 1 8 54 46 52 62 45 58 28 63 11 5 60 61 19 59 50 22 71 68 66 65 56 69 64 67 72 70 74 76 75 73 77 78
9	39 37 17 38 20 30 34 9 16 13 21 33 40 25 35 10 5 29 28 41 43 3 24 36 14 7 1 26 31 44 4 45 15 32 8 23 18 2 57 42 53 52 27 12 49 19 48 47 59 6 11 54 64 56 58 62 46 50 55 51 60 61 63 69 66 22 73 65 67 72 71 68 76 75 70 74 77 78
10	30 1 2 27 23 8 13 3 35 26 18 20 42 43 28 39 16 44 33 34 41 11 45 24 32 37 22 14 12 53 6 10 5 55 56 52 31 4 25 38 60 59 17 7 21 19 54 36 29 40 60 65 15 9 46 67 57 51 48 58 47 64 49 62 69 68 71 66 73 70 75 61 72 74 76 63 78 77

<sup>75</sup> Los valores de los costes del flujo de materiales están ponderados por el correspondiente coeficiente, que toma, en este experimento, el valor de 90000.

### 10.3.2 Resultados obtenidos en LG2

#### 10.3.2.1 Ejecución 1

#### Valores medios máximos y mínimos obtenidos en la ejecución

Coste mínimo del flujo de materiales de entre las distribuciones con mayor número de actividades geoméricamente válidas / Actividades válidas	339092,25 / 40
Coste flujo materiales medio:	342632,41
Coste flujo materiales máximo:	352681,57
Coste flujo materiales mínimo:	338562,89
Coste geométrico medio:	1,48
Coste geométrico máximo:	2,72
Coste geométrico mínimo:	0,98
Nº medio de actividades geoméricamente válidas:	34,3
Nº máximo de actividades geoméricamente válidas :	40
Nº mínimo de actividades geoméricamente válidas :	24
Generación del óptimo media:	1067,6

#### Detalle de las diferentes distribuciones obtenidas

Mejor distribución obtenida en cada ejecución <sup>76</sup>								
(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)
1	1503	35	462211,9	341002,39	121209,5	0,9	341002,39	1,21
2	1192	26	582036,5	352681,57	229354,9	0,9	352681,57	2,29
3	996	40	437152,7	339591,72	97560,96	0,9	339591,72	0,98
4	791	27	573560,8	347097,25	226463,5	0,9	347097,25	2,26
5	1256	40	437152,7	339591,72	97560,96	0,9	339591,72	0,98
6	500	38	447435,2	339092,25	108342,9	0,9	339092,25	1,08
7	978	40	437152,7	339591,72	97560,96	0,9	339591,72	0,98
8	1323	24	619930,9	348110,25	271820,6	0,9	348110,25	2,72
9	750	38	446905,8	338562,89	108342,9	0,9	338562,89	1,08
10	1387	35	462211,9	341002,39	121209,5	0,9	341002,39	1,21

Codificación de la mejor distribución de cada ejecución	
Ejecución	Código
1	ad ia ad b d b a b i a i b d a b i a a i i d i d d a d i a b i a i i a b b d
2	b d i b b d b b a a i b a a b i a a b d a a d i b d d i i b a i b a i b i a d
3	i b i d d b i b d i a b a i b b i d d b a a b a b b b i d a a d a a b i i d
4	i b i d b b i b i i a b a i b a i i d b a i b a b b b a i b a a d i i b a i d
5	i a i d d a i a d i b a b i a a i d d a b b a b a a a a i d b b d b b a i i d
6	b i d b b i a i b a d b d a i i a b b i d d i d i i i i a b a d b d d b a a i
7	d a d i i a d a i d b a b d a a d i i a b b b a a a a d i b b i b b a d d i
8	a d i a d d i d d b a a i b d a b d a a b b d a d d a a b d b i d d b a i b d
9	b d i b b d a d b a i b i a d b a i b d i i d i d d d d a b a i b i b a a d
10	b d i b b d a d b a i b i a d b a i b b i i d i d d b d i b a i b i i b a a d

<sup>76</sup> LEYENDA: (1) Ejecución, (2) Generación de la mejor distribución, (3) Número de actividades que cumplen sus restricciones geométricas, (4) Resultado de la función objetivo, (5) Coste del flujo de materiales ponderado, (6) Coste geométrico ponderado, (7) Ratio de la planta, (8) Coste del flujo de materiales, (9) Coste geométrico.

### 10.3.2.2 Ejecución 2

#### Valores medios máximos y mínimos obtenidos en la ejecución

Coste mínimo del flujo de materiales de entre las distribuciones con mayor número de actividades geoméricamente válidas / Actividades válidas	341141,47 / 40
Coste flujo materiales medio:	341346,13
Coste flujo materiales máximo:	346431,28
Coste flujo materiales mínimo:	334401,16
Coste geométrico medio:	1,37
Coste geométrico máximo:	2,68
Coste geométrico mínimo:	0,98
Nº medio de actividades geoméricamente válidas:	35,60
Nº máximo de actividades geoméricamente válidas :	40
Nº mínimo de actividades geoméricamente válidas :	22
Generación del óptimo media:	920,3

#### Detalle de las diferentes distribuciones obtenidas

Mejor distribución obtenida en cada ejecución <sup>77</sup>								
(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)
1	777	40	438702,4	341141,47	97560,97	0,9	341141,47	0,98
2	1002	34	481884,3	339659,99	142224,3	0,9	339659,99	1,42
3	432	40	438702,4	341141,47	97560,97	0,9	341141,47	0,98
4	568	39	443290,3	342953,07	100337,2	0,9	342953,07	1,00
5	478	40	438702,4	341141,47	97560,97	0,9	341141,47	0,98
6	1654	36	461930,5	341282,43	120648	0,9	341282,43	1,21
7	876	40	441728,5	344167,52	97560,97	0,9	344167,52	0,98
8	832	25	602519,1	334401,16	268117,9	0,9	334401,16	2,68
9	987	22	597237,6	346431,28	250806,3	0,9	346431,28	2,51
10	1597	40	438702,4	341141,47	97560,97	0,9	341141,47	0,98

Codificación de la mejor distribución de cada ejecución	
Ejecución	Código
1	d i a a b i d a d a a b a b b a a a d b b d d a b b d d i d d b b b b d d a i
2	i a b a d d i b i a a b a a a d d a b a i a i a b i i b i b a a b i i b d
3	i d b b a d i b i b b a b a a b b b i a a i i b a a i d i i a a a i i b d
4	d i b b a i d b d b i a b a a i b b d a a d d b a a d b i d d a a a d d b i
5	d i a a b i d a d a a b a b b a a a d b b d d a b b d d i d d b b b b d d a i
6	d d b b a d i b i b b a b a a b d d a a a i a b a a i d b i i a a a i i b d
7	d i a b a i d b d b b a b a b b b d a b d d b a a d d i d d a b a a d d b i
8	d i b b a a a b i b i i i a a i a i b a i b b b a b b b d i d d i a i d d d a
9	i d a a b b a a a b i i b d i i a b d a a a d a a b b i i d d d d a i i b
10	i d a a b d i a i a b a b b a a a i b b i i a b b i i d i i b b b b i i a d

<sup>77</sup> LEYENDA: (1) Ejecución, (2) Generación de la mejor distribución, (3) Número de actividades que cumplen sus restricciones geométricas, (4) Resultado de la función objetivo, (5) Coste del flujo de materiales ponderado, (6) Coste geométrico ponderado, (7) Ratio de la planta, (8) Coste del flujo de materiales, (9) Coste geométrico.

10.3.2.3 Ejecución 3

Valores medios máximos y mínimos obtenidos en la ejecución

Coste mínimo del flujo de materiales de entre las distribuciones con mayor número de actividades geoméricamente válidas / Actividades válidas	326623,53 / 40
Coste flujo materiales medio:	328043,18
Coste flujo materiales máximo:	334543,38
Coste flujo materiales mínimo:	326177,06
Coste geométrico medio:	1,29
Coste geométrico máximo:	2,04
Coste geométrico mínimo:	0,98
Nº medio de actividades geoméricamente válidas:	34,40
Nº máximo de actividades geoméricamente válidas :	40
Nº mínimo de actividades geoméricamente válidas :	24
Generación del óptimo media:	1780,4

Detalle de las diferentes distribuciones obtenidas

Mejor distribución obtenida en cada ejecución <sup>78</sup>								
(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)
1	1123	33	454566,7	329059,31	125507,4	0,9	329059,31	1,26
2	1062	32	468570,3	326177,06	142393,3	0,9	326177,06	1,42
3	3456	40	424184,5	326623,53	97560,97	0,9	326623,53	0,98
4	1976	32	468570,3	326177,06	142393,3	0,9	326177,06	1,42
5	3123	40	424718,9	327157,97	97560,97	0,9	327157,97	0,98
6	500	31	481863,1	334543,38	147319,7	0,9	334543,38	1,47
7	845	40	426129,7	328568,76	97560,97	0,9	328568,76	0,98
8	2478	24	533670,4	329324,11	204346,3	0,9	329324,11	2,04
9	2360	40	424184,5	326623,53	97560,97	0,9	326623,53	0,98
10	881	32	468570,3	326177,06	142393,3	0,9	326177,06	1,42

Codificación de la mejor distribución de cada ejecución	
Ejecución	Código
1	bbibbibddaaiddiibiddddba dibibiababd
2	iibia dibaaadbabbibiaadaaidabibiddia
3	dbdbad bbaiaaaiidbidbbiiadiibaibaai
4	iaibdiabbbda dbaaiabbbdbidbaiaaididdib
5	dbdaadaabibbbiidbidaaiibddiabbibiabbi
6	abdaaaaaiaabbiddbdbaiiaiaidabiabbdai
7	ibibbibbbdaaad diadibdddbiddab adbadabd
8	ddadbidabbbiidbadiaddbdbabbdiibdiib
9	dbdbad bbaiaaaiidbidbbiiadiibaibaai
10	iibia dibaaadbabbibiaadaaidabibiddia

<sup>78</sup> LEYENDA: (1) Ejecución, (2) Generación de la mejor distribución, (3) Número de actividades que cumplen sus restricciones geométricas, (4) Resultado de la función objetivo, (5) Coste del flujo de materiales ponderado, (6) Coste geométrico ponderado, (7) Ratio de la planta, (8) Coste del flujo de materiales, (9) Coste geométrico.

### 10.3.2.4 Ejecución 4

#### Valores medios máximos y mínimos obtenidos en la ejecución

Coste mínimo del flujo de materiales de entre las distribuciones con mayor número de actividades geoméricamente válidas / Actividades válidas	346739,67 / 40
Coste flujo materiales medio:	349434,73
Coste flujo materiales máximo:	361239,16
Coste flujo materiales mínimo:	330199,64
Coste geométrico medio:	1,89
Coste geométrico máximo:	2,68
Coste geométrico mínimo:	0,98
Nº medio de actividades geoméricamente válidas:	30,30
Nº máximo de actividades geoméricamente válidas :	40
Nº mínimo de actividades geoméricamente válidas :	22
Generación del óptimo media:	1299,6

#### Detalle de las diferentes distribuciones obtenidas

Mejor distribución obtenida en cada ejecución <sup>79</sup>								
(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)
1	1438	40	445826,6	348265,62	97560,97	0,9	348265,62	0,98
2	1634	22	605348	354548,09	250799,9	0,9	354548,09	2,51
3	1376	27	629652,9	361239,16	268413,8	0,9	361239,16	2,68
4	1524	22	601587,5	350787,59	250799,9	0,9	350787,59	2,51
5	995	23	590261,3	346739,67	243521,6	0,9	346739,67	2,44
6	1456	40	448118,6	350557,61	97560,97	0,9	350557,61	0,98
7	987	40	444987,5	347426,5	97560,97	0,9	347426,5	0,98
8	707	27	605110,9	360169,97	244941	0,9	360169,97	2,45
9	1513	31	493609,8	330199,64	163410,1	0,9	330199,64	1,63
10	1366	31	522506,3	344413,4	178092,9	0,9	344413,4	1,78

Codificación de la mejor distribución de cada ejecución	
Ejecución	Código
1	b a d a a a a a b b d a a a i b b d a i b a a b b b d d b i d d a i b d b i
2	a i i d i d i b i a i b i d a i a b d a i b d d a d i b i i b b d a d b i a
3	d b d i d i d i i a a i b b a d d b d a i b i a a i d b a a b b d i d i d a
4	b d i d d d i a d b d a d d b i b a d b i a d i b d i a i i a a d b i a i b
5	i i i d d i b d d b i d a d b i i a d b i a d d b d i a i b a a a i i a i b
6	b a i b b a a a a a a i a d b b i a d b b b b a a i i b d i i a d a i b d
7	a b d b b b b b b b b b b b i a a d b i a a b a b b d d a i d d b i a d a i
8	i a i d i d i d d b b d a a b i i a i b b a d b b d i a b b a a i d i d i b
9	b b a a i a b b b b d b a b b i i a a a d a i d a d a a i a b a b b d b i i d
10	a b a b i b b b b a d b i b b i a a d a b a a b a d a a i a d a a b d i i a d

<sup>79</sup> LEYENDA: (1) Ejecución, (2) Generación de la mejor distribución, (3) Número de actividades que cumplen sus restricciones geométricas, (4) Resultado de la función objetivo, (5) Coste del flujo de materiales ponderado, (6) Coste geométrico ponderado, (7) Ratio de la planta, (8) Coste del flujo de materiales, (9) Coste geométrico.

10.3.2.5 Ejecución 5

Valores medios máximos y mínimos obtenidos en la ejecución

Coste mínimo del flujo de materiales de entre las distribuciones con mayor número de actividades geoméricamente válidas / Actividades válidas	336566,41 / 40
Coste flujo materiales medio:	337513,46
Coste flujo materiales máximo:	339892,53
Coste flujo materiales mínimo:	336566,41
Coste geométrico medio:	1,58
Coste geométrico máximo:	2,96
Coste geométrico mínimo:	0,98
Nº medio de actividades geoméricamente válidas:	34,60
Nº máximo de actividades geoméricamente válidas :	40
Nº mínimo de actividades geoméricamente válidas :	25
Generación del óptimo media:	916,7

Detalle de las diferentes distribuciones obtenidas

Mejor distribución obtenida en cada ejecución <sup>80</sup>								
(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)
1	523	40	434127,4	336566,41	97560,97	0,9	336566,41	0,98
2	1083	40	434127,4	336566,41	97560,97	0,9	336566,41	0,98
3	1567	25	633633,7	337781,06	295852,7	0,9	337781,06	2,96
4	1459	36	496201,4	339892,53	156308,8	0,9	339892,53	1,56
5	773	28	506907,2	338285,01	168622,2	0,9	338285,01	1,69
6	845	36	472363,5	337679,01	134684,5	0,9	337679,01	1,35
7	653	36	472363,5	337679,01	134684,5	0,9	337679,01	1,35
8	987	25	633405	337552,33	295852,7	0,9	337552,33	2,96
9	500	40	434127,4	336566,41	97560,97	0,9	336566,41	0,98
10	777	40	434127,4	336566,41	97560,97	0,9	336566,41	0,98

Codificación de la mejor distribución de cada ejecución	
Ejecución	Código
1	i a i i b b b a i a b a d d b b b d b a d i b a d d d i i i d i i b d a d a i a
2	d b d d a a a b d b a b i i a a i a b i d a b i i d d d i d d a i b i b d b
3	d i i b d b d a a b b b b a d d i d i a i d b d b b b b i b a a d d i b a i i
4	d b d d b a i b d b a b d i a a i a d i d a b i i d d d i b d a i b i b d b
5	d a d i b i d d d a b i i d b b i b d d a b a i i b a d i b d b d a i d a a
6	d d i i a a a b i b a b d d a a d a b d i i d d d i i b i i a d b b b i b
7	d d i i b b b a i a b a d d b b b d a d i i d d d i i i a i i b d a d a i a
8	d i i a d b d a a b b b b a d d i d i a i d b d b b b b i b a a d d i b a i i
9	i a i i b b b a i a b a d d b b b d b a d i b a d d d i i i d i i b d a d a i a
10	d a d d b b b a d a b a i i b b i b a i d b a i i d d d i d d b i a i a d a

<sup>80</sup> LEYENDA: (1) Ejecución, (2) Generación de la mejor distribución, (3) Número de actividades que cumplen sus restricciones geométricas, (4) Resultado de la función objetivo, (5) Coste del flujo de materiales ponderado, (6) Coste geométrico ponderado, (7) Ratio de la planta, (8) Coste del flujo de materiales, (9) Coste geométrico.

### 10.3.2.6 Ejecución 6

#### Valores medios máximos y mínimos obtenidos en la ejecución

Coste mínimo del flujo de materiales de entre las distribuciones con mayor número de actividades geoméricamente válidas / Actividades válidas	347506,38 / 40
Coste flujo materiales medio:	348544,81
Coste flujo materiales máximo:	354907,37
Coste flujo materiales mínimo:	342294,93
Coste geométrico medio:	1,75
Coste geométrico máximo:	2,67
Coste geométrico mínimo:	0,98
Nº medio de actividades geoméricamente válidas:	31,50
Nº máximo de actividades geoméricamente válidas :	40
Nº mínimo de actividades geoméricamente válidas :	23
Generación del óptimo media:	1141,7

#### Detalle de las diferentes distribuciones obtenidas

Mejor distribución obtenida en cada ejecución <sup>81</sup>								
(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)
1	806	35	501436,1	353388,69	148047,4	0,9	353388,69	1,48
2	1205	23	620373,7	352892,18	267481,5	0,9	352892,18	2,67
3	1432	40	447603,3	350042,35	97560,97	0,9	350042,35	0,98
4	812	35	464296,8	347338,12	116958,7	0,9	347338,12	1,17
5	1073	40	445067,4	347506,38	97560,97	0,9	347506,38	0,98
6	1092	29	530184,6	344450,5	185734,1	0,9	344450,5	1,86
7	1625	25	600997,7	354907,37	246090,3	0,9	354907,37	2,46
8	743	30	541658,4	342294,93	199363,4	0,9	342294,93	1,99
9	1376	28	538447,3	346258,82	192188,5	0,9	346258,82	1,92
10	1253	30	545914,2	346368,8	199545,4	0,9	346368,8	2,00

Codificación de la mejor distribución de cada ejecución	
Ejecución	Código
1	a d i b b i b i b b b d a b i d a a b b d i a d i d i a d d d a d b d a i a
2	a b a a i i b b b b a b b i b d a a i d b d a a a i d b i a d a b d i a d
3	b a i a a i a a i a a a d b i i d b b a a d i b a i d i b i d d i d d b b i b
4	d b d b i i b b i a b b b a d d i a b d d d i b d b i i d i b d d d a a i a
5	a b i b d b b d b b d a i i i a a b b i i a b i i d a i d i i i i a a d a
6	b i a i a b a i b b i a i b b i d b d a b d a b i d i i b i b i b a a a d a d
7	a a a a i b i b i b b a b b i i b b a a a d b b a a i i b b i i d a b d i a d
8	a i b b b i b i a a a b i a a i d a b b d a a a i d i i a i i i a b b b i b d
9	b b b b a b d d d b a d d b b b b a b d b b a a b b d d a d d d b b b i d a i
10	a d a a b b a d d b b b d b a d i b a b a i b a d i d d b d d d a a b b d a i

<sup>81</sup> LEYENDA: (1) Ejecución, (2) Generación de la mejor distribución, (3) Número de actividades que cumplen sus restricciones geométricas, (4) Resultado de la función objetivo, (5) Coste del flujo de materiales ponderado, (6) Coste geométrico ponderado, (7) Ratio de la planta, (8) Coste del flujo de materiales, (9) Coste geométrico.

### 10.3.2.7 Ejecución 7

#### Valores medios máximos y mínimos obtenidos en la ejecución

Coste mínimo del flujo de materiales de entre las distribuciones con mayor número de actividades geoméricamente válidas / Actividades válidas	334837,98 / 40
Coste flujo materiales medio:	336351,19
Coste flujo materiales máximo:	345263,73
Coste flujo materiales mínimo:	334837,98
Coste geométrico medio:	1,63
Coste geométrico máximo:	2,74
Coste geométrico mínimo:	0,98
Nº medio de actividades geoméricamente válidas:	33,10
Nº máximo de actividades geoméricamente válidas :	40
Nº mínimo de actividades geoméricamente válidas :	23
Generación del óptimo media:	1441,3

#### Detalle de las diferentes distribuciones obtenidas

Mejor distribución obtenida en cada ejecución <sup>82</sup>								
(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)
1	1902	36	470789,4	345263,73	125525,6	0,9	345263,73	1,26
2	1136	40	432437,7	334876,69	97560,96	0,9	334876,69	0,98
3	1023	23	592387,1	335238,83	257148,3	0,9	335238,83	2,57
4	975	23	609692,2	336142,38	273549,8	0,9	336142,38	2,74
5	1614	40	432437,7	334876,69	97560,96	0,9	334876,69	0,98
6	1435	40	432399	334837,98	97560,97	0,9	334837,98	0,98
7	1567	23	609632,3	336420,3	273212	0,9	336420,3	2,73
8	1632	40	432437,7	334876,69	97560,96	0,9	334876,69	0,98
9	1876	40	432437,7	334876,69	97560,96	0,9	334876,69	0,98
10	1253	26	551217,5	336101,9	215115,6	0,9	336101,9	2,15

Codificación de la mejor distribución de cada ejecución	
Ejecución	Código
1	b i b b b d b a d i a b b b i i d i b i b a i a b b b d d d b d a d i a a i
2	i d a a a a b b b a b a a a a d i i i a i a d i b d a a a d d i b d i b b i
3	b b b b b d i a b a a a b b a a a d a b b i a a i d i b i i d i a a b i a d
4	d d a a a i a b d i d b d a a a b d a i i b d d d d b i i d a b d d i b d a
5	i d a a a a b b b a b a a a a d i i i a i a d i b d a a a d d i b d i b b i
6	i d a a a a b b b a b a a a a i d i a i a d d b d a a a d d i b d i b b i
7	i i a a d a b i d i b i a a b b a d d a b i i i d d d i a b i i d b i a
8	i d a a a a b b b a b a a a a d i i i a i a d i b d a a a d d i b d i b b i
9	i d b b b b b a a b a b b b d i i b i b d i a d b b b d d i d a d i a a i
10	d b b b d d b a a d a a b b a a i d a b i i d a i b b a i b i a i b i a d

<sup>82</sup> LEYENDA: (1) Ejecución, (2) Generación de la mejor distribución, (3) Número de actividades que cumplen sus restricciones geométricas, (4) Resultado de la función objetivo, (5) Coste del flujo de materiales ponderado, (6) Coste geométrico ponderado, (7) Ratio de la planta, (8) Coste del flujo de materiales, (9) Coste geométrico.



### 10.3.2.8 Ejecución 8

#### Valores medios máximos y mínimos obtenidos en la ejecución

Coste mínimo del flujo de materiales de entre las distribuciones con mayor número de actividades geoméricamente válidas / Actividades válidas	332107,48 / 40
Coste flujo materiales medio:	333147,67
Coste flujo materiales máximo:	338597,15
Coste flujo materiales mínimo:	330399,16
Coste geométrico medio:	1,18
Coste geométrico máximo:	1,54
Coste geométrico mínimo:	0,98
Nº medio de actividades geoméricamente válidas:	36,70
Nº máximo de actividades geoméricamente válidas :	40
Nº mínimo de actividades geoméricamente válidas :	32
Generación del óptimo media:	1103,1

#### Detalle de las diferentes distribuciones obtenidas

Mejor distribución obtenida en cada ejecución <sup>83</sup>								
(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)
1	895	40	429668,4	332107,48	97560,96	0,9	332107,48	0,98
2	1456	36	445580,1	332452,94	113127,1	0,9	332452,94	1,13
3	954	40	429668,4	332107,48	97560,96	0,9	332107,48	0,98
4	500	32	492365,4	338597,15	153768,2	0,9	338597,15	1,54
5	1467	40	429668,4	332107,48	97560,96	0,9	332107,48	0,98
6	1034	37	440736,4	330947,27	109789,1	0,9	330947,27	1,10
7	670	36	443526,3	330399,16	113127,1	0,9	330399,16	1,13
8	1055	32	489278,5	337955,1	151323,4	0,9	337955,1	1,51
9	1345	40	429668,4	332107,48	97560,96	0,9	332107,48	0,98
10	1655	34	478581,9	332695,19	145886,7	0,9	332695,19	1,46

Codificación de la mejor distribución de cada ejecución	
Ejecución	Código
1	a d d i i a b i i i i d i a d d d i d a b b a d a a d d i b i i i b b a d d b
2	b b d i i b a a i a d d d d d d i b b b a b d b b d b i i a a i a a d d d a
3	a i i d d a b d d d d i d a i i i d i a b b a i a a i i d b d d d b b a i i b
4	i i d d d a b d a i d d a a i d d d i a d b a i a a i d d b i b d d d b i a i b
5	a d d i i a b i i i i d i a d d d i d a b b a d a a d d i b i i i b b a d d b
6	b d d i i b a a i a i d i b d d d i b b a a b d b b d b i i a a i a d d d a
7	a a i d d a b b d b d i i i i d a a b b a i a a i a d d b b d b b i i i b
8	a i d d d a b d a i b d a a i d d d i d b a i a a i d i b i b d d d b i a i b
9	a i i d d a b d d d d i d a i i i d i a b b a i a a i i d b d d d b b a i i b
10	d i i b d b a d d d d i d b i i a d i d d i b i b b i i b a d d d a a b i i a

<sup>83</sup> LEYENDA: (1) Ejecución, (2) Generación de la mejor distribución, (3) Número de actividades que cumplen sus restricciones geométricas, (4) Resultado de la función objetivo, (5) Coste del flujo de materiales ponderado, (6) Coste geométrico ponderado, (7) Ratio de la planta, (8) Coste del flujo de materiales, (9) Coste geométrico.

### 10.3.2.9 Ejecución 9

#### Valores medios máximos y mínimos obtenidos en la ejecución

Coste mínimo del flujo de materiales de entre las distribuciones con mayor número de actividades geoméricamente válidas / Actividades válidas	343528,21 / 40
Coste flujo materiales medio:	343771,35
Coste flujo materiales máximo:	349364,63
Coste flujo materiales mínimo:	336373,91
Coste geométrico medio:	1,96
Coste geométrico máximo:	3,67
Coste geométrico mínimo:	0,98
Nº medio de actividades geoméricamente válidas:	30,30
Nº máximo de actividades geoméricamente válidas :	40
Nº mínimo de actividades geoméricamente válidas :	21
Generación del óptimo media:	1147,8

#### Detalle de las diferentes distribuciones obtenidas

Mejor distribución obtenida en cada ejecución <sup>84</sup>								
(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)
1	1420	40	442252,5	344691,54	97560,97	0,9	344691,54	0,98
2	1534	21	716721,6	349364,63	367356,9	0,9	349364,63	3,67
3	432	40	441089,2	343528,21	97560,97	0,9	343528,21	0,98
4	1093	27	556642,4	344388,32	212254,1	0,9	344388,32	2,12
5	1068	40	441089,2	343528,21	97560,97	0,9	343528,21	0,98
6	1465	32	486176,5	336373,91	149802,5	0,9	336373,91	1,50
7	957	27	556642,4	344388,32	212254,1	0,9	344388,32	2,12
8	1123	25	567971,8	342944,94	225026,8	0,9	342944,94	2,25
9	997	24	596905,6	343857,44	253048,2	0,9	343857,44	2,53
10	1389	27	594630,5	344647,97	249982,5	0,9	344647,97	2,50

Codificación de la mejor distribución de cada ejecución	
Ejecución	Código
1	ii b b d a d a b d d i b b i i d d b a b d d a d b b a a d b a i i a d i b
2	a a a a d b a d a d d b b i d b b d b i d b a b a b i i b b a d a b i b i d
3	ii b b d a d b b d d i b b i i d d b a b d d a d b b a a d b a i i a d i b
4	ii i i b d d i b d d d a d i b a a d i d d a d i b i a d b d d i i d a d a b
5	ii a a d b d a d a d d i a a i i d d a b d a d b d a a b b d a b i i b d i a
6	i a i d b b b b b b b a a b d i a d i d b a d i b i d i b i d i a d i d a b
7	d d d d b i i d b i i i a i d b a a i d i i a i d b d a i b i i d d i a i a b
8	b d a d i d d a i a i i d d a b i i d b a i d a i d b b a d a d a b d i a b d
9	a b a i i b i b i i a a b b b i d i i i i a b b i b d d i b i b a a b a b d i
10	a b b d d b d b a d a a b b b d i d d i d a b b a b i i d b b d d a b a b i d

<sup>84</sup> LEYENDA: (1) Ejecución, (2) Generación de la mejor distribución, (3) Número de actividades que cumplen sus restricciones geométricas, (4) Resultado de la función objetivo, (5) Coste del flujo de materiales ponderado, (6) Coste geométrico ponderado, (7) Ratio de la planta, (8) Coste del flujo de materiales, (9) Coste geométrico.

### 10.3.2.10 Ejecución 10

#### Valores medios máximos y mínimos obtenidos en la ejecución

Coste mínimo del flujo de materiales de entre las distribuciones con mayor número de actividades geoméricamente válidas / Actividades válidas	333782,62 / 40
Coste flujo materiales medio:	334601,28
Coste flujo materiales máximo:	338190,47
Coste flujo materiales mínimo:	332699,36
Coste geométrico medio:	1,34
Coste geométrico máximo:	2,58
Coste geométrico mínimo:	0,98
Nº medio de actividades geoméricamente válidas:	36,10
Nº máximo de actividades geoméricamente válidas :	40
Nº mínimo de actividades geoméricamente válidas :	24
Generación del óptimo media:	1129,5

#### Detalle de las diferentes distribuciones obtenidas

Mejor distribución obtenida en cada ejecución <sup>85</sup>								
(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)
1	1543	36	472582,8	338190,47	134392,3	0,9	338190,47	1,34
2	1007	36	467091,6	332699,36	134392,3	0,9	332699,36	1,34
3	1489	40	431343,6	333782,62	97560,97	0,9	333782,62	0,98
4	640	39	440280,7	336196	104084,7	0,9	336196	1,04
5	1230	34	476897,2	333211,25	143686	0,9	333211,25	1,44
6	1780	40	434725,5	337164,51	97560,96	0,9	337164,51	0,98
7	1430	40	431343,6	333782,62	97560,97	0,9	333782,62	0,98
8	1023	36	467345,2	332952,96	134392,3	0,9	332952,96	1,34
9	583	24	593510,5	335333,67	258176,9	0,9	335333,67	2,58
10	570	36	467091,6	332699,36	134392,3	0,9	332699,36	1,34

Codificación de la mejor distribución de cada ejecución	
Ejecución	Código
1	d a d b d i a b d a i i a b d d a i d d b b b b a d i d i d d b a b a a i d
2	i b d b i d b b b d b i i b a d d b i d d b a a b a i i d i d d a a b a i d
3	a d i a b d a i a i i d b b i a a a d i i a b b a b i a a b i i a b d a b d i
4	a d i a b d a i a i i d b b i a a a d b i a b b d i i a a b i i a b d a b d i
5	d a i i i i a a i i a d d a b i i a d i i b b a b d d i d i a b b b a b d i
6	b b d b a i b d b d i i a b d b b b i d d b b a b a d b b a d d b a i b a i d
7	b d i b a d b i b i d a a i b b b d i i b a a b a i b b a i i b a d b a d i
8	a b d b i d b b b d i i b a d d b i d d b a a b a i i d i d d a a b a i d
9	i b a a d b d a a i a b d d a i i d a a a b d i d b i d a i i d b a d i a
10	d b i b d i b b b i d d b a i i b d i i b a a b a d d i d i i a a b a d i

<sup>85</sup> LEYENDA: (1) Ejecución, (2) Generación de la mejor distribución, (3) Número de actividades que cumplen sus restricciones geométricas, (4) Resultado de la función objetivo, (5) Coste del flujo de materiales ponderado, (6) Coste geométrico ponderado, (7) Ratio de la planta, (8) Coste del flujo de materiales, (9) Coste geométrico.



# 11

**Bibliografía**

## **Bibliografía**

- Acosta-Buitrago M.A. y Zuluaga-Muñoz, C. A., "Tutorial sobre redes neuronales aplicadas en ingeniería eléctrica y su implementación en un sitio web", documento electrónico disponible en: <http://ohm.utp.edu.co/neuronales/>, fecha de último acceso: March/2005
- Adam, E.E. y Ebert, R.J., "Production and operation management, concepts, models and behavior", Edit.: Prentice-Hall International Editions, New York, 1992
- Adenso-Díaz, B., Glover, F., Ghaziri, H., González, J.M., Laguna, M., Moscato, P., y Tseng, F., "Optimización Heurística y Redes Neuronales en Dirección de Operaciones e Ingeniería", Edit.: Paraninfo, Madrid, 1996
- Al Hakim L., "On a genetic algorithm approach for multiple criteria facility layout design", International Journal of Production Research, 38, pp: 985-989, 1999
- Al Hakim L., "On solving facility layout problems using genetic algorithms", International Journal of Production Research, 38, pp: 2573-2582, 2000
- Aleksander, I. y Morton, H., "An introduction to neural computing", Edit.: Chapman & Hall, Londres, 1990
- Andrés, C., "Programación de la producción en talleres de flujo híbridos con tiempos de cambio de partida dependientes de la secuencia. Modelos, métodos y algoritmos de resolución. Aplicación a empresas del sector cerámico", Tesis doctoral, Universidad Politécnica de Valencia, 2001
- Andrés C., Molins A., Vicens E., y Albarracín J. M., "Equilibrado de líneas mediante un algoritmo de búsqueda tabú. Aplicación a una empresa del sector del automóvil", XXIV Congreso nacional de estadística e investigación operativa, Almería, 1998
- Anstreicher K.M., Brixiu, N.W., Linderoth, J., y Goux, P., "Solving large quadratic assignment problems on computational grids", Mathematical Programming, 91, pp: 563-588, 2002
- Antonisse H.J., "A new interpretation of the schemata notation that overturns the binary encoding constraint", Third International Conference on Genetic Algorithms, San Mateo, 1989
- Aparisi-Navarro J.E., "Aplicación del método de la asignación laboral (MEDAL) para la gestión de las rotaciones ergonómicas (método MORE)", IV Congreso de seguridad y salud en el trabajo de la Comunidad Valenciana, Valencia, 2005
- Apple, J.M., "Plant layout and material handling", Edit.: John Wiley & Sons, Nueva York, 1977

- Apple J.M. y Deisenroth M. P., "A computerized plant layout analysis and evaluation technique (PLANET)", AIIE technical papers, 2.c., Anaheim, California, 1972
- Arabas J., Michalewicz, Z., y Mulawka, J.J., "GAVaPS - A genetic algorithm with varying population size", Actas de la International Conference on Evolutionary Computation, pp: 73-78, 1994
- Arapoglu R.A., Norman, B.A., y Smith, A.E., "Locating input and output points in facilities design – A comparison of constructive, evolutionary, and exact methods", IIE Transactions on Evolutionary Computation, 5, pp: 192-203, 2001
- Armour G.C. y Buffa, E.S., "A heuristic algorithm and simulation approach to relative location of facilities", Management Science, 9, pp: 294-309, 1963
- Atmar W., "Notes on the simulation evolution", IEEE Transactions on neural networks, 5, pp: 130-147, 1994
- Azadivar F. y Wang, J., "Facility layout optimization using simulation and genetic algorithms", International Journal of Production Research, 38, pp: 4369-4383, 2000
- Balakrishnan J., Cheng, C.H., y Wong, K.F., "FACOPT: a user friendly FACility layout OPTimization system", Computers & Operations Research, 30, pp: 1625-1641, 2003a
- Balakrishnan J., Jacobs, F.R., y Venkataramanan, M.A., "Solutions for the constrained dynamic facility layout problem", European Journal of Operational Research, 57, pp: 280-286, 1992
- Balakrishnan J.D., Cheng, C.H., Conway, D.G., y Lau, C.M., "A hybrid genetic algorithm for the dynamic plant layout problem", International Journal of Production Economics, 86, pp: 107-120, 2003b
- Banerjee P., Montreuil, B., Moodie, C.L., y Kashyap, R.L., "A Modelling of Interactive Facilities Layout Designer Reasoning Using Qualitative Patterns", International Journal of Production Research, 30, pp: 433-453, 1992
- Banerjee P. y Zhou, Y., "Facilities layout design optimization with single loop material flow path configuration", International Journal of Production Research, 33, pp: 183-204, 1995
- Barbosa-Povoa A.P., Mateus, R., y Novais, A.Q., "Optimal 3D layout of industrial facilities", International Journal of Production Research, 40, pp: 1669-1698, 2002
- Baykasoglu A. y Gindy, N.N.Z., "A simulated annealing algorithm for dynamic layout problem", Computers & Operations Research, 28, pp: 1403-1426, 2001

- Bazaraa M.S. y Kirca, O., "A branch and bound based heuristic algorithm for solving the QAP", *Naval Research Logistics Quarterly*, 30, pp: 287-304, 1983
- Bazaraa M.S. y Sherali, H.D., "New approaches for solving the quadratic assignment problem", *Operational Research Verfahren*, 32, pp: 29-46, 1979
- Benson B. y Foote, B.L., "DoorFAST: A constructive procedure to optimally layout a facility including aisles and door locations based on an aisle flow distance metric", *International Journal of Production Research*, 35, pp: 1825-1842, 1997
- Block T.E., "A note on "Comparision of computer algorithms and visual based methods for plant layout" by M.Scriabin and R.C. Vergin", *Management Science*, 24, pp: 235-237, 1977
- Block T.E., "Fate: A new construction algorithm for facilities layout", *Journal of engineering production*, 2, pp: 111-120, 1978
- Block T.E., "On the complexity of facilities layout problems", *Management Science*, 25, pp: 280-285, 1979
- Blum C. y Roli, A., "Metaheuristics in combinatorial optimization: overview and conceptual comparison", *ACM Computing Surveys*, 35, pp: 268-308, 2003
- Bölte A. y Thonemann, U.W., "Optimizing simulated annealing schedules with genetic programming", *European Journal of Operational Research*, 92, pp: 402-416, 1996
- Boswell S.G., "TESSA - A new greedy heuristic for facilities layout planning", *International Journal of Production Research*, 30, pp: 1957-1968, 1992
- Bousonocalzon C. y Manning, M.R.W., "The Hopfield neural-network applied to the quadratic assignment problem", *Neural Computing and Applications*, 3, pp: 64-72, 1995
- Bozer Y.A. y Meller, R.D., "An improvement-type layout algorithm for single and multiple-floor facilities", *Management Science*, 40, pp: 918-932, 1994
- Bozer Y.A. y Meller, R.D., "A reexamination of the distance-based facility layout problem", *IEE Transactions*, 29, pp: 549-560, 1997
- Brad L.M. y Goldberg, D.E., "Optimal sampling for genetic algorithms", *Artificial Neural Networks in Engineering*, 6, pp: 291-298, 1996
- Bramlette M.F., "Initialisation , mutation and selection methods in genetic algorithm for function optimization", *Belew, R.K. y Booke, L.B., Morgan Kauffman* 1991
- Buffa E.S., "Sequence analysis for functionals layouts", *The Journal of Industrial Engineering*, Marzo, pp: 12-25, 1955



- Cameron D.C., "Travel charts", *Modern material handling magazine*, pp: 37-40, 1952
- Carrie A.S., Moore, J.M., Roczniak, M., y Seppanen, J.J., "Graph theory and computer aided facilities design", *Omega*, 6, pp: 353-361, 1978
- Cavin L., Fischer, U., Glover, F., y Hungerbuhler, K., "Multi-objective process design in multi-purpose batch plants using a Tabu Search optimization algorithm", *Computers & Chemical Engineering*, 28, pp: 459-478, 2004
- Cerny V., "Themodynamical approach to the travelling salesman problem: An efficient simulation algorithm", *Journal of Optimisation Theory and Applications*, 45, pp: 41-51, 1985
- Chakrapani J. y Skorin-Kopov, J., "Massively parallel tabu search for the quadratic assignment problem", *Annals of operations research*, 41, pp: 327-342, 1993
- Chambers, L.D.E., "Practical handbook of genetic algorithm: Applications. Volume 1", Edit.: Chapman & Hall/ CRC, Florida, 1995a
- Chambers, L.D.E., "Practical handbook of genetic algorithm: New Frontiers. Volume 2", Edit.: Chapman & Hall/ CRC, Florida, 1995b
- Chambers, L.D.E., "Practical handbook of genetic algorithm: Complex Coding System. Volume 3", Edit.: Chapman & Hall/ CRC, Florida, 1999
- Chen C.W. y Sha, D.Y., "A design approach to the multiple-objective facility layout problem", *International Journal of Production Research*, 37, pp: 1175-1196, 1999
- Chen Y.K., Lin, S.W., y Chou, S.Y., "An efficient two-staged approach for generating block layouts", *Computers & Operations Research*, 29, pp: 489-504, 2002
- Chiang W. y Kouvelis, P., "An improved tabu search heuristic for solving facility layout design problems", *International Journal of Production Research*, 34, pp: 2565-2585, 1996
- Chittratanawat S. y Noble, J.S., "An integrated approach for facility layout", *International Journal of Production Research*, 37, pp: 683-706, 1999
- Cohon J.P., Hedge, W.N., Martin, W.N., y Richards, D.S., "Distributed genetic algorithms for the floorplant design problem", *IEEE Transactions on Computer-Aided Design*, 10, pp: 483-492, 1991
- Coit D.W., Smith, A.E., y Tate, D.M., "Adaptative penalty methods for genetic optimization of constrained combinatorial problems", *Journal on computing*, 8, pp: 173-182, 1996

- Colomi A., Dorigo M., y Maniezzo V., "An investigation of some properties of an 'ant algorithm'", Proceedings of the Parallel Problem Solving from Nature Conference (PPSN 92), Elsevier Science Publisher, Bruselas, 1992
- Colomi A., Dorigo, M., Maffioli, F., Maniezzo, V., Righini, M., y Trubian, M., "Heuristics from nature for hard combinatorial optimization problems", International Transactions in Operational Research, 3, pp: 1-21, 1996
- Commander C.W., "A survey of the quadratic assignment problem with applications", Morehead Electronic Journal of Applicable Mathematics,4, disponible en <http://www.morehead-st.edu/colleges/science/math/mejam/>, 2005
- Connolly D.T., "An improved annealing schema for the QAP", European Journal of Operational Research, 46, pp: 93-100, 1990
- Contero-González, M., "Aportación a la optimización del diseño geométrico de plantas industriales, distribución en planta", Tesis doctoral, Universidad Politécnica de Valencia, 1995
- Conway D.G. y Venkataramanan, M.A., "Genetic search and the dynamic facility layout problem", Computers and Operations Research, 21, pp: 955-960, 1994
- Cuatrecasas-Arbós, L., "Diseño de procesos de producción flexible", Edit.: TPG-Hoshin, Madrid, 1996
- Current J., Min, H., y Schilling, D., "Multiobjective analysis of facility location decision", European Journal of Operational Research, 49, pp: 295-307, 1990
- Davis L., "Applying adaptative algorithms to epistatic domains", Proc.of the international joint conference on artificial intelligence, pp: 162-164, 1985
- Davis L., "Adapting operator probabilities in genetic search", Proceedings of the third international conference on genetic algorithms , San Mateo, 1989
- Davis, L., "Handbook of Genetic Algorithms", Edit.: Van Nostrand Reinhold, New York, 1991
- De Jong K.A., "Genetic algoritms: a 10 years perspective", Proceedings of the first international conference on genetic algorithms, San Mateo, 1985
- De Jong, K.A., "Genetic algorithms are not function optimizers", Edit.: Morgan Kaufmann, San Mateo, California, 1993
- De Jong, K.A. y Spears, W.M., "An analysis of the interacting roles of population size and crossover in genetic algorithms", Edit.: Springer-Verlag, 1990

- De la Fuente D., Gómez A., y García N., "Técnicas heurísticas para optimizar la colocación de superficies rectangulares dentro de una superficie", III Jornadas de Ingeniería de Organización, Barcelona, 1999
- De-Heredia, R., "Arquitectura y urbanismo industrial", Edit.: Sección de publicaciones de la Escuela Técnica Superior de Ingenieros Industriales de Madrid, 1981
- Díaz J.A. y Fernandez, E., "A Tabu search heuristic for the generalized assignment problem", *European Journal of Operational Research*, 132, pp: 22-38, 2001
- Digalakis J.G. y Margaritis, K.G., "An experimental study of benchmarking functions for genetic algorithms", *IEEE Conferences Transactions, Systems, Man and Cybernetics*, 5, pp: 3810-3815, 2000
- Dorigo , M., "Ottimizzazione, apprendimento automatico, ed algoritmi basati su metafora naturale", Tesis doctoral, Politecnico di Milano, Milán, 1992
- Dorigo M. y Gambardella, L.M., "Ant colony system: a cooperative learning approach to the traveling salesman problem", *IEEE Transactions on Evolutionary Computation*, 1, pp: 53-66, 1997
- Dorigo M. y Gambardella, L.M., "Ant colonies for the travelling salesman problem", *BioSystems*, 43, pp: 73-81, 1997
- Dorigo M., Maniezzo, V., y Colomi, A., "The ant system: optimization by a colony of cooperating agents", *IEEE Transactions on Systems*, 26, pp: 1-13, 1996
- Dowlatahahi S., "A modelling approach to design of integrated facilities", *International Journal of Production Research*, 32, pp: 1313-1330, 1994
- Downsland, K.A., "Simulated annealing", *Modern heuristics techniques for combinatorial problems*, Edit: Blackwell Scientific Publishers: Oxford, 1993a
- Downsland K.A., "Some experiments with Simulated Annealing Techniques for Packing Problems", *European Journal of Operational Research*, 68, pp: 389-399, 1993b
- Drezner Z., "A new genetic algorithm for the quadratic assignment problem", *Inform journal on computing*, 15, pp: 320-330, 2003
- Drezner Z., "The extended concentric tabu for the quadratic assignment problem", *European Journal of Operational Research*, 160, pp: 422, 2005
- Dudek G. y Scheuer, T., "Threshold accepting: a general purpose optimization algorithm", *Journal of Computational Physics*, 90, pp: 161-175, 1990

- Dunker T., Radons, G., y Westkamper, E., "Combining evolutionary computation and dynamic programming for solving a dynamic facility layout problem", *European Journal of Operational Research*, 165, pp: 55-69, 2005
- Dunlop A.E. y Kernigan, B.W., "A procedure for placement of standard cell VLSI circuits", *IEEE Transactions on Computer-Aided Design*, 10, pp: 483-492, 1985
- Dyckhoff H., "A typology of cutting and packing problems", *European Journal of Operational Research*, 44, pp: 145-159, 1990
- Edwards H.K., Gillett, B.E., y Halle, M.E., "Modular allocation technique (MAT)", *Management Science*, 17, pp: 161-169, 1970
- Efron B., "Bootstrap methods: Another look at the jackknife", *The Annals of Statistics*, 7, pp: 1-26, 1979
- Eshelman, L., "The CHC adaptative search algorithm", Edit.:Morgan-Kaufmann, 1991
- Eshelman, L., Caruna, R., y Schaffer, J.D., "Biases in the crossover landscape", Edit.:Morgan Kaufmann, San Mateo, 1989
- Fleurent C. y Ferland, J.A., "Quadratic Assignment and Related Problems: genetic hybrids for the quadratic assignment problem", *DIMACS series in discrete mathematics and theoretical computer science*, 16, pp: 173-187, 1994
- Fogarty T.C., "Varying the probability of mutation in genetic algorithm", *Proceedings of the third international conference on genetic algorithms*, San Mateo, 1989
- Fogel D.B., "An introduction to simulated evolutionary optimization", *IEEE Transactions on neural networks*, 5, pp: 3-14, 1994
- Fogel D.B. y Fogel, L.J., "Guest editorial; evolutionary computation", *IEEE Transactions on neural networks*, 5, pp: 1-2, 1994
- Fogel, L.J., Owens, A.J., y Walsh, M.J., "Artificial intelligence through simulated evolution", Edit.: Wiley Publishing, New York, 1966
- Foulds L.R. y Robinson, D.F., "A strategy for solving the plant layout problem", *Operational Research Quarterly*, 27, pp: 845-855, 1976
- Foulds L.R. y Robinson, D.F., "Graph theoretic heuristic for the plant layout problem", *International Journal of Production Research*, 16, pp: 27-37, 1978
- Francis, R.L. y White J.A., "Facility layout and location, an analytical approach", Edit.:Prentice-Hall INC., 1974

- 
- Gambardella L.M., Taillard, E., y Dorigo, M., "Ant colonies for the quadratic assignment problem", *Journal of the Operational Research Society*, 50, pp: 167-176, 1999
- Garey, M.R. y J.D.S., "Computers and intractability: A guide to the Theory of NP-Completeness", Edit.: W. H. Freeman and Company, San Francisco, 1979
- Gau K.Y. y Meller, R.D., "An iterative facility layout algorithm", *International Journal of Production Research*, 37, pp: 3739-3758, 1999
- Gilmore P.C., "Optimal and suboptimal algorithms for the quadratic assignments problem", *SIAM Journal on applied mathematics*, 10, pp: 305-313, 1962
- Glover F., "Future paths for integer programming and links to artificial intelligence", *Computers & Operations Research*, 13, pp: 533-549, 1986
- Glover F., "Tabu search - Part 1", *ORSA Journal on computing*, 1, pp: 190-206, 1989
- Glover F., "Tabu search - Part 2", *ORSA Journal on computing*, 2, pp: 4-32, 1990
- Glover F., "Simple Tabu Thresholding in Optimization", Research Report, School of Business, University of Colorado, 1991
- Glover F. y Melián, B., "Tabu search", *Inteligencia Artificial, Revista Iberoamericana de Inteligencia Artificial.*, 19, pp: 29-48, 2003
- Glover F., Taillard, E., y Werra, D., "A user's guide to tabu search", *Annals of operations research*, 41, pp: 3-28, 1993
- Glover F., Kelly, J.P., y Laguna, M., "Genetic algorithm and tabu search: hybrids for optimization", *Computers & Operations Research*, 22, pp: 111-134, 1995
- Goldberg D.E., "Alleles, loci and the TSP", *Proceedings of the first international conference on genetic algorithms*, San Mateo, 1985
- Goldberg, D.E., "Genetic Algorithms in search, optimization and machine learning.", Edit.: Addison-Wesley Publishing Company Inc., Massachusetts, 1989a
- Goldberg, D.E., "Genetic algorithms in search, optimization and machine learning.", Edit.: Addison-Wesley Publishing Company Inc., Massachusetts, 1989b
- Goldberg, D.E., "The theory of virtual alphabets", *Proceedings of the parallel problems solving from nature workshop*, Edit: Schwefel, H.P. y Reinhard, M.: Dortmund, pp: 13-22, 1991

- Goldberg D.E., Kargupta H., Horn J., y Cantu-Paz E., "Critical Deme Size For Serial And Parallel Genetic Algorithms", Technical Report IlliGAL 95002, 1995
- Gómez A., Fernández, Q.I., García, D.D.L., y García, P.J., "Using genetic algorithms to resolve layout problems in facilities where there are aisles", *International Journal of Production Economics*, 84, pp: 271-282, 2003
- Gómez-Senent, E., "El proyecto: diseño en ingeniería.", Edit.:Universidad Politécnica de Valencia, Valencia, 1997
- Gómez-Senent E., Santamarina M., Chiner M., Aragonés P., y Capuz S., "The Design Dimensions. A Design Theory Proposal.", 11th International Conference on Engineering Design ICED, Tampere, 1997
- Gomory R.E., "Outline of an algorithm for integer solutions to linear programs", *Bulletin of the American Mathematical Society*, 64, pp: 275-278, 1958
- Gomory, R.E., "An algorithm for integer solutions to linear programs", *Recent Advances in Mathematical Programming*, Edit: McGraw-Hill: Nueva York, pp: 269-302, 1963
- González-Cruz, M.C., "Implantación y aplicación de una estrategia general de resolución de problemas basada en la teoría de las dimensiones del proyecto para la elaboración de una metodología de resolución de layout. Estructuración de las técnicas necesarias.", Tesis doctoral, Universidad Politécnica de Valencia, 2001
- González-García, J.L., "Aportación a la optimización multiobjetivo de la distribución en planta", Tesis doctoral, Universidad Politécnica de Valencia, 2005
- Green R.C., "Geometry, shoemaking and milk tray problem.", *New Scientist*, August 12, pp: 50-51, 1989
- Green R.H. y Al Hakim, L., "A heuristic for facilities layout planning", *Omega*, 13, pp: 469-474, 1985
- Grefenstette J., "Optimization of control parameters for genetics algorithms", *IEEE Transactions on systems, man and cybernetics*, 16, pp: 122-128, 1986
- Grefenstette J., "A User's Guide to GENESIS Version 5.0", documento electrónico disponible en: <http://www.genetic-programming.com/c2003genesisgrefenstette.txt>, fecha de último acceso: 1990
- Hamamoto S., Yih, Y., y Salvendy, G., "Development and validation of genetic algorithm-based facility layout - a case study in the pharmaceutical industry", *International Journal of Production Research*, 37, pp: 749-768, 1999

- 
- Hammouche A. y Webster, D.B., "Evaluation of an application of graph theory to the layout problem", *International Journal of Production Research*, 23, pp: 987-1000, 1985
- Hanafi, R., "Design of a genetic algorithm to solve the facility layout problem", Tesis doctoral, IRIS, Swinburne University of Technology, Melbourne, 2000
- Harmonosky C.M. y Totho, G.K., "A multi-factor plant layout methodology", *International Journal of Production Research*, 30, pp: 1773-1789, 1992
- Hasegawa M., Ikeguchi, T., Aihara, K., y Itoh, K., "A novel chaotic search for quadratic assignment problems", *European Journal of Operational Research*, 139, pp: 543-556, 2002
- Hassan M.M.D. y Hogg, G.L., "A review of graph theory applications to the facilities layout problem", *Omega*, 14, pp: 291-300, 1987
- Hassan M.M.D. y Hogg, G.L., "On converting a dual graph into a block layout", *International Journal of Production Research*, 27, pp: 1149-1160, 1989
- Hassan M.M.D. y Hogg, G.L., "On constructing a block layout by graph theory", *International Journal of Production Research*, 29, pp: 1263-1278, 1991
- Hassan M.M.D., Hogg, G.L., y Smith, D.R., "SHAPE: A construction algorithm for area placement evaluation", *International Journal of Production Research*, 24, pp: 12-1283, 1986
- Hebb, D.O., "The organization of behaviour", Edit.: John Wiley & Sons, Nueva York, 1949
- Heragu S.S., "Recent models and techniques for solving the layout problem", *European Journal of Operational Research*, 57, pp: 136-144, 1992
- Heragu, S.S., "Facilities design", Edit.: PWS Publishing Company, Boston, 1997
- Heragu S.S. y Alfa, A.S., "Experimental analysis of simulated annealing based algorithm for the facility layout problems", *European Journal of Operational Research*, 52, pp: 190-202, 1992
- Heragu S.S. y Kusiack, A., "Efficient models for the facility layout problem", *European Journal of Operational Research*, 53, pp: 1-13, 1991
- Herroelen W. y Van Gils, A., "On the use of flow dominance in complexity measures for facility layout problems", *International Journal of Production Research*, 23, pp: 97-108, 1985
- Hicks C., "A genetic algorithm tool for designing manufacturing facilities in the capital goods industry", *International Journal of Production Economics*, 90, pp: 199-211, 2004

- Hillier F.S., "Quantitative tools for plant layout analysis", *The Journal of Industrial Engineering*, 14, pp: 33-40, 1963
- Hillier F.S. y Connors, M.M., "Quadratic assignment problem algorithms and location of indivisible facilities", *Management Science*, 13, pp: 42-57, 1966
- Hinterding, R., Gielewski, H., y Peachey, T.C., "The nature of mutation in genetic algorithms", Edit.:Morgan Kaufmann, San Mateo, 1995
- Hitchings G.G., "Control, redundancy and change in layout systems", *AIIE Transactions*, 2, pp: 253-260, 1970
- Hitchings G.G. y Cottam, M., "An efficient heuristic procedure for solving the layout design problem", *Omega*, 4, pp: 205-214, 1976
- Holland, J.H., "Adaptation in natural and artificial systems", Edit.: University of Michigan Press, Ann Arbor, 1975
- Hopfield J.J. y Tank, D.W., "Neural computation of decisions in optimization problems", *Biological cybernetics*, 52, pp: 141-152, 1985
- Hospitaller A. y Cano, J.J., "Algoritmo para la mejora de las distribuciones en planta por secciones, atendiendo a criterios de coste relacional", *Anales de Ingeniería Mecánica*, 4, pp: 183-187, 1986
- Huntley C.L. y Brown, D.E., "A parallel heuristic for quadratic assignment problems", *Computers and Operations Research*, 18, pp: 275-289, 1991
- Immer, R.J., "Materials Handling", Edit.: McGraw-Hill, New York, 1953
- Ishii S. y Sato, M., "Constrained neural approaches to quadratic assignment problems", *Neural Networks*, 11, pp: 1073-1082, 1998
- Islier A.A., "A genetic algorithm approach for multiple criteria facility layout design", *International Journal of Production Research*, 36, pp: 1549-1569, 1998
- Jakobs S., "On genetic algorithms for the packing of polygons", *European Journal of Operational Research*, 88, pp: 165-181, 1996
- Janikow C.Z. y Michalewicz Z., "An experimental comparison of binary and floating point representations in genetic algorithm", Morgan Kauffman, 1991
- Johnson D.S., Aragon, C.R., McGeoch, L.A., y Schevon, C., "Optimization by simulated annealing: An experimental evaluation; Part I, Graph colouring and number partitioning", *Operations Research*, 37, pp: 865-892, 1989



- Johnson D.S., Aragon, C.R., McGeoch, L.A., y Schevon, C., "Optimization by simulated annealing: An experimental evaluation; Part II, Graph colouring and number partitioning", *Operations Research*, 39, pp: 378-406, 1991
- Johnson R.V., "SPACECRAFT for multi-floor layout planning", *Management Science*, 28, pp: 407-417, 1982
- Jones D.F., Mirrazavi, S.K., y Tamiz, M., "Multi-objective meta-heuristics: An overview of the current state-of-the-art", *European Journal of Operational Research*, 137, pp: 1-9, 2002
- Jones, T., "Crossover, macromutation, and population-based search", Edit.:Morgan Kaufmann, San Mateo, 1995
- Kado K., Ross P., y Corne D., "A study of genetic algorithm hybrids for facility layout problems", *Proc.of the sixth international conference on genetic algorithms*, San Mateo, 1995
- Kaufman L. y Broeckx, F., "An algorithm for the quadratic assignment problem using Bender's decomposition", *European Journal of Operational Research*, 2, pp: 204-211, 1978
- Kettani O. y Oral, M., "Reformulating quadratic assignment problem for efficient optimization", *IEE Transaction*, 25, pp: 97-107, 1993
- Khalil T.M., "Facilities relative allocation technique (FRAT)", *International Journal of Production Research*, 11, pp: 183-194, 1973
- Kim J.G. y Kim, Y.D., "A space partitioning method for facility layout problems with shape constraints", *IIE Transactions*, 30, pp: 947-957, 1998
- Kim J.G. y Kim, Y.D., "Layout planning for facilities with fixed shapes and input and output points", *International Journal of Production Research*, 38, pp: 4635-4653, 2000
- Kirkpatrick S., Gelatt, C.D., y Vecchi, M.P., "Optimization by Simulated Annealing", *Science*, 220, pp: 671-680, 1983
- Koakutsu S., Kang M., y Dai W. W.-M., "Genetic simulated annealing and application to non-slicing floorplan design", *Technical Report of the Jack Baskin School of Engineering, U.o.C., Santa Cruz*, 1995
- Kochhar J.S. y Heragu, S.S., "MULTI-HOPE: a tool for multiple floor layout problems", *International Journal of Production Research*, 36, pp: 3421-3435, 1998
- Koopmans T.C. y Beckmann, M., "Assignment problems and the location of economic activities", *Economics*, 25, pp: 52-76, 1957

- Kouvelis P., Chiang, W., y Fitzsimmons, J., "Simulated annealing for machine layout problems in the presence of zoning constraints", *European Journal of Operational Research*, 57, pp: 203-223, 1992
- Kuik R. y Salomon, M., "Multi-item lot-sizing problem: evaluation of a simulated annealing heuristic", *European Journal of Operational Research*, 45, pp: 25-37, 1990
- Kuppusamy, S., "Simulated annealing heuristics for the dynamic facility layout problem", Tesis doctoral, West Virginia University, 2001
- Kusiack A. y Heragu, S.S., "The facility layout problem", *International Journal of Production Research*, 29, pp: 229-251, 1987
- Lacksonen T.A., "Preprocessing for static and dynamic facility layout problems", *International Journal of Production Research*, 35, pp: 1095-1106, 1997
- Land A.M., "A problem of assignment with interrelated costs", *Operational Research Quarterly*, 14, pp: 185-198, 1963
- Lario Esteban, F.C., "Planificación de la producción. Aplicación de los modelos de investigación operativa", Edit.:Servicio de publicaciones de la Universidad Politécnica de Valencia, Valencia, 1993
- Lawler E.L., "The quadratic assignment problem", *Management Science*, 9, pp: 586-599, 1963
- Lee K.Y., Han, S.N., y Roh, M.I., "An improved genetic algorithm for facility layout problems having inner structure walls and passages", *Computers & Operations Research*, 30, pp: 117-138, 2003
- Lee K.Y., Roh, M.I., y Jeong, H.S., "An improved genetic algorithm for multi-floor facility layout problems having inner structure walls and passages", *Computers & Operations Research*, 32, pp: 879-899, 2005
- Lee R. y Moore, J.M., "CORELAP-computerized relationship layout planning", *Journal of Industrial Engineering*, 18, pp: 195-200, 1967
- Lee Y.H. y Lee, M.H., "A shape-based block layout approach to facility layout problems using hybrid genetic algorithm", *Computers & Industrial Engineering*, 42, pp: 237-248, 2002
- Levary R.R. y Kalchick, S., "Facilities layout-a survey of procedures", *Computers & Industrial Engineering*, 9, pp: 141-148, 1985
- Levin P.H., "Use of graphs to decide the optimum layout of buildings", *The Architects' Journal Information Library*, Octubre, pp: 809-815, 1964

- Liggett R.S. y Mitchell, W.J., "Optimal Space Planning in Practice", *Computer Aided Design*, 13, pp: 277-288, 1981
- Lin J.L. y Chang C. H., "Solving multiple floor facility layout problems by genetic search", 5th annual international conference on industrial engineering theory, a.a.p., San Antonio, 2000
- Loiola E.M., Abreu, N. M. M, Boaventura-Netto, P. O., Hahn, P., y Querido, T., "An analytical survey for the quadratic assignment problem", documento electrónico disponible en: [http://www.seas.upenn.edu/qaplib/QAP\\_Survey\\_04.pdf#search='boaventura%20net](http://www.seas.upenn.edu/qaplib/QAP_Survey_04.pdf#search='boaventura%20net) to, fecha de último acceso: 2004
- Lundy M. y Mees, A., "Convergence of an annealing algorithm", *Mathematical Programming*, 34, pp: 124-, 1986
- Malakooti B., "Multiple objective facility layout: a heuristic to generate efficient alternatives", *International Journal of Production Research*, 27, pp: 1225-1238, 1989
- Maniezzo V., "Exact and approximate nondeterministic tree-search procedures for the quadratic assignment problem", *Journal on computing*, 11, pp: 358-369, 1999
- Maniezzo V. y Colomi, A., "The ant system applied to the quadratic assignment problem", *IEEE Transactions on Knowledge and Data Engineering*, 11, pp: 769-778, 1999
- Maniezzo V., Dorigo M., y Colomi A., "The ant system applied to the quadratic assignment problem", Technical Report IRIDIA/94-28 de la Universite Libre de Bruxelles, Bruselas, 1994
- Maniezzo V., Dorigo , M., y Colomi, A., "ALGODESK: An experimental comparison of eight evolutionary heuristics applied to the Quadratic Assignment Problem", *European Journal of Operational Research*, 81, pp: 188-204, 1995
- Martín, B. y Sanz, A., "Redes neuronales y sistemas borrosos", Edit.:RA-MA, 1997
- Martins V.C., dos-Santos, L., Barbosa, M.A., y Ferrari, R., "Optimização de layouts industriais com base em busca tabu", *Gestão & Produção*, 10, pp: 69-88, 2003
- Mathias, K.E., Whitley L.D., Stork, C., y Kusuma, T., "Staged hybrid genetic search for seismic data imaging", *IEEE conference on evolutionary computation*, 1, pp: 356-361, 1994
- Matson J.O., Mellichamp, J.M., y Swaminathan, S.R., "EXCITE: Expert consultant for in-plant transportation equipment", *International Journal of Production Research*, 8, pp: 1969-1983, 1992

- Matsuzaki K., Irohara, T., y Yoshimoto, K., "Heuristic algorithm to solve the multi-floor layout problem with the consideration of elevator utilization", *Computers & Industrial Engineering*, 36, pp: 487-502, 2005
- Mavridou T.D. y Pardalos, P.M., "Simulated Annealing and Genetic Algorithms for the Facility Layout Problem: A Survey", *Computational Optimization and Applications*, 7, pp: 111-126, 1997
- Mayr, E., "Toward a new philosophy of biology: observations of an evolutionist", Edit.:Belknap Press, Cambridge, 1988
- McCulloch W.S. y Pitts, W., "A logical calculus of idea's immanent in nervous activity", *Bulletin of Mathematical Biophysics*, 5, pp: 115-133, 1943
- Meller R.D. y Bozer, Y.A., "A new simulated annealing algorithm for the facility layout problem", *International Journal of Production Research*, 34, pp: 1675-1692, 1996a
- Meller R.D. y Bozer, Y.A., "Alternative approaches to solve the multi-floor facility layout problem", *Journal of Manufacturing Systems*, 16, pp: 192-203, 1997
- Meller R.D. y Gau, K.Y., "Facility layout objective functions and robust layouts", *International Journal of Production Research*, 34, pp: 2727-2742, 1996b
- Meller R.D. y Gau, K.Y., "Facility layout problem: Recent and emerging trends and perspectives", *Journal of Manufacturing Systems*, 15, pp: 351-366, 1996c
- Metropolis N., Rosenblund, A.W., Rosenblund, M.N., Teller, A.H., y Teller, E., "Equation of State Calculations by Fast Computing Machines", *Journal of Chemical Physics*, 21, pp: 1087-1092, 1953
- Michalewicz, Z., "Genetic algorithms + data structures = evolution programs", Edit.: Springer-Verlag, New York, 1992
- Minsky, M. y Papert, S., "Perceptrons: an introduction to computational geometry", Edit.:MIT Press, Cambridge, 1969
- Misevicius A., "A modification of tabu search and its applications to the quadratic assignment problem", *Information Technology and Control*, 27, pp: 20-, 2003a
- Misevicius A., "A modified simulated annealing algorithm for the quadratic assignment problem", *Informatica*, 14, pp: 497-514, 2003b
- Misevicius A., "Genetic algorithm hybridized with ruin and recreate procedure: application to the quadratic assignment problem", *Knowledge-Based Systems*, 16, pp: 268-, 2003c

- Misevicius A., Rubliauskas, D., y Smolinskas, J., "Reconstruct and improve principle based algorithm for the quadratic assignment problem.", *Information Technology and Control*, 23, pp: 7-17, 2002
- Mojena R., Vollmann, T.E., y Okamoto, Y., "On predicting computational time of a branch-and-bound algorithm for the assignment of facilities", *Decision Science*, 7, pp: 856-867, 1976
- Moore, J.M., "Plant layout and design", Edit.:MacMillan Company, New York, 1962
- Moore J.M., "Facilities design with graph theory and strings", *Omega*, 4, pp: 193-203, 1976
- Muhlenbein, H., "Evolution in time and space-the parallel genetic algorithm", *Foundations of Genetic Algorithms*, Edit: Rawlins, G., Los altos, 1991
- Muther, R., "Planificación y proyección de la empresa industrial (Método SLP)", Edit.: Técnicos Asociados S.A., Barcelona, 1968
- Muther, R., "Distribución en planta", Edit.:McGraw Hill, New York, 1981
- Muther R. y McPherson, K., "Four approaches to computerized layout planning", *Journal of Industrial Engineering*, February, 1970
- Muther, R. y PcPherson, K., "Systematic planning of industrial facilities - S.P.I.F.", Edit.:Management and industrial research publications, Kansas City, 1979
- Nissen V., "Solving the quadratic assignment problem with clues from Nature", *IEEE Transactions on neural networks*, 5, pp: 66-72, 1994
- Nugent C.E., Vollmann, T.E., y Ruml, J., "An experimental comparison of techniques for the assignment of facilities to locations", *Operations Research*, 16, pp: 150-173, 1968
- Obuchi Y., Masui, H., y Ohki, M., "Weighted parallel problem solving by optimization networks.", *Neural Networks*, 9, pp: 357-366, 1996
- Ontiveros, R., "Algoritmo interactivo de solución al problema de distribución en planta, con control de forma y con empleo de técnicas de análisis de decisiones multicriterio discretas", Tesis doctoral, Universidad Politécnica de Valencia, 2005
- Osman I.H., "Metastrategy simulated annealing and tabu search algorithms for the vehicle routing problems", *Annals of operations research*, 41, pp: 421-451, 1993
- Osman I.H., "An introduction to Meta-Heuristics", *Operational Research, Tutorial Papers*, pp: 92-122, 1995

- Ozdemir G., Smith, A.E., y Norman, B.A., "Incorporating heterogeneous distance metrics within block layout design", *International Journal of Production Research*, 41, pp: 1045-1056, 2003
- Pérez A., "Una introducción a la computación evolutiva", documento electrónico disponible en: <ftp://ftp.de.uu.net/pub/research/softcomp/EC/EA/papers/intro-spanish.ps.gz>, fecha de último acceso: Noviembre /2004
- Preux P. y Talbi, E.-G., "Towards hybrid evolutionary algorithms", *International Transactions in Operational Research*, 6, pp: 557-570, 1999
- Quenouille M., "Approximation test of correlation in time series", *Journal of the Royal Statistical Society*, 11, pp: 18-84, 1949
- Radcliffe N.J., "Equivalence Class Analysis of Genetic Algorithms", *Complex Systems*, 5, pp: 183-205, 1991a
- Radcliffe, N.J., "Formal Analysis and Random Respectful Recombination", *Proceedings of the Fourth International Conference on Genetic Algorithms*. San Mateo, CA, Edit: Belew, R.K. y Booke, L.B., 1991b
- Rajasekharan M., Peters, A., y Yang, T., "A genetic algorithm for facility layout design in flexible manufacturing systems", *International Journal of Production Research*, 36, pp: 95-110, 1998
- Raoot A.D. y Rakshit, A., "A "linguistic pattern" approach for multiple criteria facility layout problems", *International Journal of Production Research*, 31, pp: 203-204, 1993a
- Raoot A.D. y Rakshit, A., "An experimental comparison of systematic placement procedures for facility layout design", *International Journal of Production Research*, 31, pp: 1735-1756, 1993b
- Rechenberg, I., "Evolutionsstrategie: Optimierung Technischer Systeme nach Prinzipien der Biologischen Evolution", Edit.: Stuttgart, 1973
- Reeves C.R., "Genetic Algorithms and Combinatorial Optimization", *Applications of Modern Heuristic Techniques*, Alfred Waller Ltd, 1994
- Rodriguez J.M., Macphee F. C., Bonham D. J., y Bhavsar V. C., "Solving the quadratic assignment and dynamic plant layout problems using a new hybrid meta-heuristic approach", 2004
- Romero C., González, P, y Ventura, S., "Algoritmos Evolutivos (Red Española de Procedimientos Metaheurísticos HEUR )", documento electrónico disponible en: <http://heur.uv.es/ventana/tutorial.php?idPagina=12&idioma=SPA>, fecha de último acceso: Noviembre /2004

- Rosenblatt F., "The Perceptron: a probabilistic model for information storage and organization in the brain", *Psychological Review*, 65, pp: 386-408, 1958
- Rosenblatt M.J., "The facilities layout problem: a multi-goal approach", *International Journal of Production Research*, 17, pp: 323-332, 1979
- Rosenblatt M.J., "The dynamics of plant layout", *Management Science*, 32, pp: 76-86, 1986
- Rosenblatt M.J. y Sinuany-Stern, Z., "A discrete efficient frontier approach to the plant layout problem", *Material Flow*, 3, pp: 277-281, 1986
- Rossin D.F., Springer, M.C., y Klein, B.D., "New complexity measures for the facility layout problem: an empirical study using traditional and neural network analysis", *Computers & Industrial Engineering*, 36, pp: 585-602, 1999
- Rudolph G., "Convergence analysis of canonical genetic algorithms", *IEEE Transactions on neural networks*, 5, pp: 96-101, 1994
- Salhi S., "Defining tabu list size and aspiration criterion within tabu search methods", *Computers & Operations Research*, 29, pp: 67-86, 2002
- Santamarina, M.C., "Métodos de optimización en la generación de distribuciones de plantas industriales mediante la aplicación de algoritmos genéticos y técnicas basadas en árboles de corte", Tesis doctoral, Universidad Politécnica de Valencia, 1995
- Schaffer J.D., Caruna R., Eshelman L., y Das R., "A study of control parameters affecting online performance of genetic algorithms for function optimization", *Proceedings of the Third International Conference on Genetic Algorithms*, San Mateo, 1989
- Schaffer J.D. y Morishima A., "An adaptative crossover mechanism for genetic algorithms", *Proc.of the second international conference on genetic algorithms*, San Mateo, 1987
- Schell, T., "A comparison of selection methods in genetic algorithms based on a set of selection metrics.", Tesis doctoral, Universit at Salzburg, Salzburg, 1998
- Schmidt, W.F., "Neural Pattern Classifying Systems", Tesis doctoral, Delft University of Technology, Delft, 1994
- Schwefel, H.P., "Numerical optimization of computer models", Edit.: John Wiley & Sons., New York, 1981
- Scriabin M. y Vergin, R.C., "Comparison of computer algorithms and visual based methods for plant layout", *Management Science*, 22, pp: 172-181, 1975
- Scriabin M. y Vergin, R.C., "A cluster-analytic approach to facility layout", *Management Science*, 31, pp: 33-49, 1985

- Sedgewick, R. y Flajolet, P., "An Introduction to the Analysis of Algorithms", Edit.: Addison-Wesley, Massachusetts, 1996
- Seehof J.M. y Evans, W.O., "Automated layout design program", Journal of Industrial Engineering, 18, pp: 690-695, 1967
- Seppanen J.J. y Moore, J.M., "Facilities planning with graph theory", Management Science, 17, pp: 242-253, 1970
- Shayan E. y Chittilappilly, A., "Genetic algorithm for facilities layout problems based on slicing tree structure", International Journal of Production Research, 42, pp: 4055-4067, 2004
- Shebanie, C.R., "An integrated, evolutionary approach to facility layout and detailed design", Tesis doctoral, University of Pittsburgh, 2002
- Simmons D.M., "One dimensional space allocation: an ordering algorithm", Operations Research, 17, pp: 812-826, 1969
- Simon, H.A., "Style in Design", Spatial Synthesis in Computer-Aided Building Design, Edit: Eastman, C.M.: Nueva York, 1975
- Skorin-Kopov J., "Tabu search applied to the quadratic assignment problem", ORSA Journal on computing, 2, pp: 33-45, 1990
- Skorin-Kopov J., "Extensions of a tabu search adaptation to the quadratic assignment problem", Computers and Operations Research, 21, pp: 855-865, 1994
- Smith R.E., Goldberg, D.E., y Earickson, J.A., "SGA-C: A C-language Implementation of a Simple Genetic Algorithm", The Clearinghouse for Genetic Algorithms, TCGA Report No. 91002, 1991
- Solimanpur M., Vrat, P., y Shankar, R., "An ant algorithm for the single row layout problem in flexible manufacturing systems", Computers and Operations Research, 32, pp: 583-598, 2005
- Spears W.M., De Jong, K.A., Bäck, T., Fogel, D.B., y e Garis, H., "An Overview of Evolutionary Computation", Proceedings of the European Conference on Machine Learning, Viena, pp: 442-459, 1993
- Srinivas M. y Patnaik, L.M., "Adaptative probabilities of crossover and mutation in genetic algorithms", IEEE Transactions on systems, man and cybernetics, 24, pp: 656-667, 1994a
- Srinivas M. y Patnaik, L.M., "Genetic algorithms: a survey", IEEE Computer, 27, pp: 17-26, 1994b



- Stützle, T. y Dorigo, M., "Local search and metaheuristics for the quadratic assignment problem. Technical report", Edit.:Darmstadt University of Technology, Alemania, 2001
- Suh J.Y. y Van Gucht D., "Incorporating heuristic information into genetic search", Proceedings of the second international conference on genetic algorithms, San Mateo, 1987
- Sule, D.R., "Manufacturing facilities: Location planning and design", Edit.: PWS Publishing, Boston, 1994
- Sule, D.R., "Instalaciones de Manufactura", Edit.: Thomson Learning, Boston, 2000
- Suresh G. y Sahu, S., "Multiobjetive facility layout using simulated annealing", International Journal of Production Economics, 32, pp: 239-254, 1993
- Suresh G., Vinod, V.V., y Sahu, S., "A genetic algorithm for facility layout", International Journal of Production Research, 33, pp: 3411-3423, 1995
- Syswerda G., "Uniform crossover in genetic algorithms", Proc.of the third international conference on genetic algorithms, San Mateo, 1989
- Syswerda, G., "A study of reproduction in generational and steady-state genetic algorithms", Edit.: Morgan Kauffmann Publishers, 1991
- Tabu Search Applications, "Tabu search applications", documento electrónico disponible en: [http://www.tabusearch.net/tabu\\_search/applications.asp](http://www.tabusearch.net/tabu_search/applications.asp), fecha de último acceso: Agosto /2004
- Taillard E., "Robust tabu search for the quadratic assignment problem", Parallel computing, 17, pp: 443-455, 1991
- Taillard E. y Gambardella L. M., "Adaptive memories for the quadratic assignment problem", Technical Report IDSIA-87-97, Lugano, 1997
- Taillard E., Gambardella, L.M., Gendreau, M., y Potvin, J.Y., "Adaptive memory programming: A unified view of metaheuristics", European Journal of Operational Research, 135, pp: 1-16, 2001
- Takefuji, Y., "Neural network parallel computing", Edit.:Kluwer Academic Publishers, Boston, 1992
- Talbi E.G., Hafidi, Z., y Geib, J.M., "A parallel adaptive tabu search approach", Parallel computing, 24, pp: 2003-2019, 1998

- Talbi E.G., Roux, O., Fonlupt, C., y Robillard, D., "Parallel ant colonies for the quadratic assignment problem", *Future Generation Computer Systems*, 17, pp: 441-449, 2001
- Tam K.Y., "A simulated annealing algorithm for allocating space to manufacturing cells", *International Journal of Production Research*, 30, pp: 63-87, 1992a
- Tam K.Y., "Genetic Algorithms, function optimization, and facility layout design", *European Journal of Operational Research*, 63, pp: 322-346, 1992b
- Tam K.Y., "Genetic algorithms, function optimization, and facility layout design", *European Journal of Operational Research*, 63, pp: 322-346, 1992c
- Tam K.Y. y Chan, S.K., "Solving facility layout problems with geometric constraints using parallel genetic algorithms: experimentation and findings", *International Journal of Production Research*, 36, pp: 3253-3272, 1998
- Tam K.Y. y Li, S.G., "A hierarchical approach to the facility layout problem", *International Journal of Production Research*, 29, pp: 165-184, 1991
- Tate D.M. y Smith, A.E., "Unequal-area facility layout by genetic search", *AIIE Transactions*, 27, pp: 465-472, 1995
- Tompkins J.A. y Reed, R., "An applied model for the facilities design problem", *International Journal of Production Research*, 14, pp: 583-595, 1976
- Tompkins, J.A. y White, J.A., "Facilities planning", Edit.: John Wiley & Sons, New York, 1984
- Tompkins, J.A., White, J.A., Bozer, Y.A., y Tanchoco, J.M.A., "Facilities planning", Edit.: John Wiley & Sons, New York, 2003
- Tong, X., "SECOT: a sequential construction technique for facility design", Tesis doctoral, University of Pittsburgh, 1991
- Tsuchiya K., Bharitkar, S., y Takefuji, Y., "A neural network approach to facility layout problems", *European Journal of Operational Research*, 89, pp: 556-563, 1996
- Upton D.M., "The management of manufacturing flexibility", *California Management Review*, Winter, pp: 72-89, 1994
- Van Camp D.J., Carter, M.W., y Vannelli, A., "A nonlinear optimization approach for solving facility layout problems", *European Journal of Operational Research*, 57, pp: 174-189, 1991
- Vollmann T.E. y Buffa, E.S., "The facilities layout problem in perspective", *Management Science*, 12, pp: 450-468, 1966

- 
- Vollmann T.E., Nugent, C.E., y Zartler, R.L., "A computerized model for office layout ", *Journal of Industrial Engineering*, 19, pp: 321-327, 1968
- Wang M.J., Hu, M.H., y Ku, M.Y., "A solution to the unequal area facilities layout problem by genetic algorithm", *Computers in Industry*, 56, pp: 207-220, 2005
- Wen-Hsing, L., "Tabu search heuristics for the dynamic facility layout problem", Tesis doctoral, West Virginia University, 2005
- Whitley D. y Kauth, J., "Genitor: a different genetic algorithm", *Proc.Rocky Mountain conf.artificial intelligence*, pp: 118-130, 1988
- Whitley D. y Starkweather, D., "GENITOR-II: a distributed genetic algorithm", *Journal of Experimental and Theoretical Artificial Intelligence*, 2, pp: 189-214, 1990
- Wu Y. y Appleton, E., "The optimization of block layout and aisle structures by a genetic algorithm", *Computers & Industrial Engineering*, 41, pp: 371-387, 2002
- Youssef H., Sait, M., y Adiche, H., "Evolutionary algorithms, simulated annealing and tabu search: a comparative study", *Engineering Applications of Artificial Intelligence*, 14, pp: 167-181, 2001
- Zanakis S.H. y Evans, J.R., "Heuristic optimization: why, when and how to use it", *Interfaces*, 5, 1981
- Zhang G.Q., Xue, J., y Lai, K.K., "A class of genetic algorithm for multiple-level warehouse layout problems", *International Journal of Production Research*, 40, pp: 731-744, 2002
- Zoller K. y Adendroff, K., "Layout Planning by Computer Simulation", *AIIE Transactions*, 4, pp: 116-125, 1972

En Valencia, a 28 de Enero de 2006.