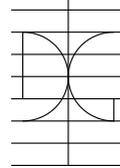


UNIVERSIDAD POLITÉCNICA DE VALENCIA

Departamento de Ingeniería de la Construcción y Proyectos de Ingeniería Civil



TESIS DOCTORAL

Optimización multiobjetivo de la distribución en planta de procesos industriales. Estudio de objetivos.

PRESENTADA POR:

D. José Miguel Montalvá Subirats

Ingeniero Industrial

DIRIGIDA POR:

D. Antonio Hospitaler Pérez

Dr. Ingeniero Industrial

Valencia, Mayo 2011

A Ana, Miguel y Jorge.

Al cruzar la línea de meta, con la entrega de esta tesis, y echar la vista atrás uno se da cuenta del largo camino recorrido. Son muchos los años de dedicación, en mayor o menor medida, muchos cambios en la orientación de la investigación, muchas dudas sobre el qué y el cómo, aunque sin duda el resultado ha merecido la pena.

En esta mirada hacia atrás, la primera mención tiene que ser necesariamente para mis padres, Jose Luis y Pilar, a los que debo lo que soy. Vuestros ánimos y ejemplo durante todos estos años siempre me ha dado ese empujón para que la rueda no parara. También agradecer a mis hermanas Ana y Pilar, que han aguantado el malhumor y las desatenciones en parte ocasionadas por el trabajo.

Por supuesto, todo esto nunca se hubiera materializado sin el incansable trabajo de mi director, que ha tirado (casi materialmente) de mí durante estos años. Gracias Toni, por todas tus ideas, conocimientos, energía y sobretodo comprensión y por ser como eres.

Trabajar en un ambiente agradable y donde siempre te dan facilidades para poder dedicarle más horas a la tesis es importantísimo, y eso se han encargado durante este tiempo Jota, Paco, Tomás, David y sobretodo Héctor, gracias a todos por vuestra ayuda.

Me he dejado para el final a las personas que más han sufrido junto a mí este largo camino que ha llegado a su fin. Ana, que pacientemente ha aguantado mis idas y venidas con la tesis, que nos ha acompañado a viajes, vacaciones, mudanzas... convirtiéndose en un miembro más de la familia, gracias por aguantarme, quererme y apoyarme durante todos estos años.

Y a Miguel, que es el motor que mueve nuestras vidas, la alegría hecha personita y el mayor acicate para alcanzar metas, y por supuesto a Jorge, que desde ahí arriba seguro que tiene una buena parte de culpa de todo lo que ocurre aquí abajo.

En el proceso de diseño de las construcciones industriales, es de vital importancia conocer cual es la ubicación óptima de las diferentes áreas de trabajo que conforman un proceso de fabricación, así como de las instalaciones y servicios auxiliares. El problema de distribución en planta (*Facilities Layout Problem, FLP*) integra a todas las actividades industriales y se ha convertido desde los años 60 en uno de los problemas clásicos de optimización combinatoria, en el que trabajan multitud de investigadores a nivel internacional. Hasta los años 90, el enfoque que se realizaba del problema era básicamente un enfoque monoobjetivo, en el que se primaba fundamentalmente la minimización del coste de transporte de material o personas entre las diferentes áreas productivas o de servicios. Para ello se han venido empleando diferentes técnicas de optimización heurística, que persiguen minimizar el tiempo de cálculo y facilitar la búsqueda de mínimos, aunque sean locales, pues el espacio de soluciones es tan grande, que es difícil garantizar la existencia de un mínimo global del problema.

No obstante, el criterio de coste no es el único que se debe considerar en este tipo de planteamientos, pues existen otra serie de indicadores que son de vital importancia, para garantizar que la solución propuesta tiene un nivel de factibilidad adecuado. Durante la última década, debido en parte al mayor desarrollo tecnológico con la aparición de equipos y programas informáticos más desarrollados, han prosperado las aproximaciones multiobjetivo al problema de distribución en planta.

Entre los objetivos principales del presente trabajo se encuentran; la realización de un estado del arte de los indicadores que se han empleado en la bibliografía para la resolución en planta, obteniendo un conjunto de indicadores independientes y suficientes que puedan ser empleados en la obtención de distribuciones en planta óptimas. Se investigará si es necesario definir algún nuevo indicador que cubra los objetivos fundamentales de la distribución en planta establecidos por distintos autores.

Una vez seleccionados los indicadores se propone una técnica de optimización multiobjetivo basada en un algoritmo de recocido simulado (*Simulated Annealing*). La técnica emplea un conjunto de soluciones que son "indiferentes" es decir, que son buenas desde el punto de vista de los diferentes criterios que se empleen en la optimización, constituyendo la denominada frontera de Pareto. Esto hace que la técnica de optimización sea más compleja, pues hay que considerar todos los parámetros que la controlan tantas veces como criterios se consideren.

Finalmente se presentan los resultados de los experimentos realizados, empleando la técnica de optimización multiobjetivo propuesta, sobre un problema ampliamente utilizado en la bibliografía, el propuesto por Armour y Buffa de 20 actividades. Se obtienen las fronteras de Pareto para diferentes bicriterios, introduciendo puntos que completan las existentes hasta la actualidad, estudiando la posibilidad de extender la optimización a 3 indicadores.

En el procés de disseny de les construccions industrials, és de vital importància conèixer quina és la ubicació òptima de les diferents àrees de treball que conformen un procés de fabricació, així com de les instal·lacions i serveis auxiliars. El problema de distribució en planta (Facilities Layout Problem, FLP) integra totes les activitats industrials i s'ha convertit des dels anys 60 en un dels problemes clàssics d'optimització combinatòria, en el qual treballen multitud d'investigadors a nivell internacional. Fins als anys 90, l'enfocament que es realitzava del problema era bàsicament un enfocament monobjectiu, en el qual es prevaluia fonamentalment la minimització del cost de transport de material o persones entre les diferents àrees productives o de serveis. Per això s'han vingut emprant diferents tècniques d'optimització heurística, que persegueixen minimitzar el temps de càlcul i facilitar la recerca de mínims, encara que siguin locals, ja que l'espai de solucions és tan gran, que és difícil garantir l'existència d'un mínim global del problema.

No obstant, el criteri de cost no és l'únic que s'ha de considerar en aquest tipus de plantejaments, ja que hi ha una altra sèrie d'indicadors que són de vital importància, per garantir que la solució proposada té un nivell de factibilitat adequat. Durant l'última dècada, degut en part al major desenvolupament tecnològic amb l'aparició d'equips i programes informàtics més desenvolupats, han prosperat les aproximacions multiobjectiu al problema de distribució en planta.

Entre els objectius principals del present treball es troben; la realització d'un estat de l'art dels indicadors que s'han emprat en la bibliografia per a la resolució en planta, obtenint un conjunt d'indicadors independents i suficients que puguin ser emprats en l'obtenció de distribucions en planta òptimes. S'investigarà si és necessari definir algun nou indicador que cobreixi els objectius fonamentals de la distribució en planta que estableix diferents autors.

Un cop seleccionats els indicadors es proposa una tècnica d'optimització multiobjectiu basada en un algorisme de recuit simulat (Simulated Annealing). La tècnica utilitza un conjunt de solucions que són "indiferents" és a dir, que són bones des del punt de vista dels diferents criteris que s'empren en l'optimització, constituint l'anomenada frontera de Pareto. Això fa que la tècnica d'optimització sigui més complexa, ja que cal considerar tots els paràmetres que la controlen tantes vegades com criteris es considerin.

Finalment es presenten els resultats dels experiments realitzats, utilitzant la tècnica d'optimització multiobjectiu proposada, sobre un problema àmpliament utilitzat en la bibliografia, el proposat per Armour i Buffa de 20 activitats. S'obtenen les fronteres de Pareto per a diferents bicriterios, introduint punts que completen les existents fins a l'actualitat, estudiant la possibilitat d'estendre la optimització a 3 indicadors.

Abstract.

On the design process of industrial construction, is vitally important to know which is the optimum location of different areas of work that make up a manufacturing process and facilities and auxiliar services. The Facilities Layout Problem, so called FLP integrates all industrial activities and has become since the 60's in one of the classic problems of combinatorial optimization, in which many international researchers works. Until the 90's, the approach to the problem was basically a single objective approach, which is clear focused on minimizing the cost of transporting materials or people between the different production and service areas. Using heuristic optimization techniques, which seek to minimize the computation time and facilitate the search for minimal, although local, since the solution space is so large, it is difficult to guarantee the existence of a global minimum.

However, the criterion of cost is not the only thing to consider in this type of approach, because there are a set of indicators that are vital to ensure that the proposed solution has a proper feasibility level. During the last decade, due in part to increased technological development with the advent of computers and software more developed, have thrived multiobjective approaches to the problem of plant distribution.

The main objectives of this work are: the creation of a state of the art of the indicators have been used in the literature for the resolution on the ground, getting a set of independent enough that can be used in obtaining distributions optimal plan. We will investigate whether to define a new indicator covering the fundamental objectives of the physical layout provided by different authors.

Once selected the set of indicators a new multi-objective optimization technique based on simulated annealing algorithm will be proposed. The technique uses a set of solutions that are "indifferent", that are good from the point of view of the different criteria used in the optimization, constituting the so-called Pareto frontier. This makes the optimization technique more complex because we must consider all the parameters that control it as many times as criteria are considered.

Finally, we present the results of experiments, using the proposed multi-objective optimization technique, for a widely used problem in the literature, the Armour and Buffa problem of 20 activities. Different Pareto frontiers are obtained introducing complementary points to the historical frontier, exploring the possibility of extending the optimization to 3 indicators.

ÍNDICE

| | | |
|------------|--|-----------|
| 1 | INTRODUCCIÓN AL PROBLEMA | 1 |
| 1.1 | Introducción y objetivos | 3 |
| 1.1.1 | Objetivos de la investigación..... | 5 |
| 1.1.2 | Estructura de los contenidos..... | 6 |
| 1.2 | El problema de distribución en planta | 8 |
| 1.2.1 | Tipos básicos de distribución en planta | 8 |
| 1.2.1.1 | Posición fija..... | 9 |
| 1.2.1.2 | Por secciones, por proceso o desplazamiento lento. | 10 |
| 1.2.1.3 | En cadena, en serie o desplazamiento rápido. | 10 |
| 1.2.1.4 | En sistemas de fabricación flexibles, por grupos homogéneos o por familia de productos. | 11 |
| 1.2.2 | Metodologías clásicas para la resolución del problema de distribución en planta | 13 |
| 1.2.2.1 | Primeras aproximaciones | 13 |
| 1.2.2.1.1 | Immer | 13 |
| 1.2.2.1.2 | "Sequence analysis" de Buffa | 13 |
| 1.2.2.1.3 | "Systematic plan of attack" de Reed..... | 15 |
| 1.2.2.1.4 | "Ideal systems approach" de Nadler..... | 15 |
| 1.2.2.1.5 | Metodología de Apple | 16 |
| 1.2.2.2 | Systematic Layout Planning (SLP) | 17 |
| 1.2.2.2.1 | Fase de definición | 19 |
| 1.2.2.2.2 | Fase de Análisis | 22 |
| 1.2.2.2.3 | Fase de Síntesis | 24 |
| 1.2.2.2.4 | Fase de Evaluación..... | 24 |
| 1.2.2.2.5 | Fase de Selección | 25 |
| 1.2.2.2.6 | Fase de Instalación..... | 25 |
| 1.2.2.3 | Métodos de generación de layouts | 26 |
| 1.2.2.3.1 | Métodos exactos (óptimos)..... | 27 |
| 1.2.2.3.2 | Heurísticas específicas del problema..... | 28 |
| 1.2.2.3.3 | Metaheurísticas | 30 |
| 2 | ASPECTOS GEOMÉTRICOS DEL PROBLEMA DE DISTRIBUCIÓN EN PLANTA..... | 35 |
| 2.1 | Modelos de representación espacial..... | 38 |
| 2.1.1 | Modelos topológicos..... | 39 |
| 2.1.1.1 | Aspectos básicos de la teoría de grafos..... | 40 |
| 2.1.1.2 | Aplicación al problema de distribución en planta | 44 |
| 2.1.2 | Modelos geométricos | 45 |
| 2.1.2.1 | Modelos de una dimensión (SRLP) | 45 |
| 2.1.2.2 | Modelos de dos dimensiones (FLP) | 46 |
| 2.1.2.2.1 | Modelos discretos..... | 47 |
| 2.1.2.2.2 | Modelos continuos | 52 |
| 2.1.2.3 | Modelos de dos dimensiones y media (MFLP) | 68 |
| 2.1.2.4 | Modelos de tres dimensiones | 76 |

| | |
|---|------------|
| 2.2 Métrica de la distancia..... | 77 |
| 2.2.1 Distancia entre centroides | 78 |
| 2.2.2 Distancia por contorno lateral..... | 81 |
| 2.2.3 Distancia por camino más corto | 81 |
| 2.2.4 Distancia rectilínea esperada (EDIST) | 82 |
| | |
| 3 INDICADORES APLICADOS AL PROBLEMA DE DISTRIBUCIÓN EN PLANTA | 83 |
| | |
| 3.1 Objetivos, principios e indicadores | 86 |
| 3.1.1 Objetivos | 87 |
| 3.1.1.1 Muther | 87 |
| 3.1.1.2 Otros autores | 89 |
| 3.1.2 Principios | 91 |
| | |
| 3.2 Indicadores empleados en el problema de distribución en planta | 95 |
| 3.2.1 Indicadores Cualitativos | 96 |
| 3.2.1.1 Índice de cercanía (Closeness Rating) | 96 |
| 3.2.1.2 Flexibilidad | 97 |
| 3.2.1.3 Adyacencia | 99 |
| 3.2.1.4 Movimientos peligrosos..... | 99 |
| 3.2.2 Indicadores Cuantitativos..... | 100 |
| 3.2.2.1 Indicadores de Flujo | 100 |
| 3.2.2.1.1 Coste de transporte de materiales (MHC) | 100 |
| 3.2.2.1.2 Tiempo de movimiento de los materiales (MMT)..... | 100 |
| 3.2.2.1.3 Indicadores de flujo de Lin y Sharp | 101 |
| 3.2.2.1.4 Circulación | 106 |
| 3.2.2.2 Indicadores Geométricos | 108 |
| 3.2.2.2.1 Indicadores de Perímetro..... | 110 |
| 3.2.2.2.2 Indicadores de Compacidad | 116 |
| 3.2.2.2.3 Indicadores de Robustez | 119 |
| 3.2.2.2.4 Indicadores de Forma..... | 121 |
| 3.2.2.2.5 Indicadores de Inercia | 128 |
| 3.2.2.3 Indicadores de aprovechamiento de área | 130 |
| | |
| 3.3 Relación Objetivos-principios-indicadores | 133 |
| | |
| 3.4 Selección de los indicadores a emplear | 138 |
| 3.4.1 Indicadores de flujo | 140 |
| 3.4.2 Indicadores geométricos | 141 |
| 3.4.2.1 Indicadores de perímetro | 145 |
| 3.4.2.2 Indicador de robustez | 146 |
| 3.4.2.3 Indicador de compacidad..... | 147 |
| 3.4.2.4 Indicadores de forma | 148 |
| 3.4.2.5 Relación con el indicador propuesto | 149 |
| 3.4.3 Indicadores seleccionados..... | 151 |

| | | |
|------------|---|------------|
| 4 | MÉTODOS DE OPTIMIZACIÓN MULTI OBJETIVO | 153 |
| 4.1 | Optimización multiobjetivo | 156 |
| 4.2 | Técnicas no basadas en Pareto | 159 |
| 4.2.1 | Agregación de objetivos | 160 |
| 4.2.2 | Método de programación por metas | 161 |
| 4.2.3 | Método de las restricciones ϵ | 162 |
| 4.2.4 | VEGA (Vector Evaluated Genetic Algorithm) | 163 |
| 4.2.5 | Ordenamiento Lexicográfico | 164 |
| 4.2.6 | Algoritmos MiniMax | 165 |
| 4.3 | Técnicas basadas en Pareto | 166 |
| 4.3.1 | Algoritmos Evolutivos Multi-Objetivo - MOEA | 167 |
| 4.3.1.1 | MOGA (Multi Objective Genetic Algorithm) | 168 |
| 4.3.1.2 | NSGA (Nondominated Sorting Genetic Algorithm) y NSGA-II | 169 |
| 4.3.1.3 | NPGA (Niche-Pareto Genetic Algorithm) y NPGA-II | 170 |
| 4.3.1.4 | SPEA (Strength Pareto Evolutionary Algorithm) y SPEA-II | 171 |
| 4.3.1.5 | PAES (Pareto Archived Evolution Strategy) | 171 |
| 4.3.1.6 | PESA (Pareto Envelope-based Selection Algorithm) y PESA-II | 172 |
| 4.3.1.7 | MOMGA (Multi Objective Messy Genetic Algorithm) y MOMGA-II | 172 |
| 4.3.1.8 | MicroGA (Micro Algoritmo Genetico MicroGA) y MicroGA-II | 173 |
| 4.3.2 | Sistemas Inmunes Artificiales Multi-Objetivo - MOAIS | 174 |
| 4.3.3 | Colonias de Hormigas Multi-Objetivo - MOACO | 175 |
| 4.3.4 | Enjambre de partículas Multi-Objetivo (Particle Swarm Optimization) | 175 |
| 4.3.5 | Algoritmos Meméticos Multi-Objetivo | 176 |
| 4.3.6 | Scatter Search Multi-Objetivo | 178 |
| 4.3.7 | Evolución Diferencial Multi-Objetivo | 179 |
| 4.3.7.1.1 | No basadas en Pareto | 181 |
| 4.3.7.1.2 | Basadas en Pareto | 182 |
| 4.3.7.1.3 | Combinadas | 183 |
| 4.4 | Simulated Annealing Multiobjetivo - MOSA | 184 |
| 4.4.1 | Los primeros pasos | 185 |
| 4.4.2 | UMOSA (Método de Ulungu y Teghem) | 186 |
| 4.4.3 | PSA (Pareto Simulated Annealing, Czyzak) | 188 |
| 4.4.4 | SMOSA (Método de Suppapitnarm y Parks) | 190 |
| 4.4.5 | NAM y PARK | 191 |
| 4.4.6 | WMOSA (Weighted based Multi-Objective Simulated Annealing) | 194 |
| 4.4.7 | PDMOSA (Pareto Dominated Multi-Objective Simulated Annealing) | 195 |
| 4.4.8 | MC-MOSA (Multi Cooling Multi-Objective Simulated Annealing) | 197 |
| 4.4.9 | AMOSA | 198 |
| 4.4.10 | EMOSA | 200 |
| 4.4.11 | MCMOSA | 201 |
| 4.4.12 | DBMOSA | 202 |

| | | |
|-----------|---|------------|
| 5 | PLANTEAMIENTO MULTI OBJETIVO DEL PROBLEMA DE DISTRIBUCIÓN EN PLANTA .. | 205 |
| 5.1 | Clasificación de las técnicas multiobjetivo aplicadas al problema de distribución en planta | 212 |
| 5.1.1 | Clasificación de Waghodekar y Sahu | 212 |
| 5.1.2 | Clasificación de Malakooti | 215 |
| 5.1.3 | Clasificación propuesta | 218 |
| 5.2 | Evaluación de soluciones | 219 |
| 5.3 | Optimización de soluciones | 222 |
| 5.3.1 | Métodos basados en funciones agregadas | 225 |
| 5.3.1.1 | Función objetivo agregada aditiva | 225 |
| 5.3.1.2 | Función objetivo agregada multiplicativa | 247 |
| 5.3.2 | Métodos basados en frontera de Pareto | 253 |
| 6 | METODOLOGÍA PROPUESTA | 261 |
| 6.1 | Construcción de soluciones | 264 |
| 6.1.1 | Aspectos Geométricos | 265 |
| 6.1.1.1 | Caracterización del recinto | 265 |
| 6.1.1.1.1 | Tamaño del recinto | 265 |
| 6.1.1.1.2 | Aspectos formales del recinto | 265 |
| 6.1.1.2 | Modelo geométrico empleado | 268 |
| 6.1.1.3 | Tamaño de la discretización | 268 |
| 6.1.2 | Colocación de Actividades | 269 |
| 6.1.2.1 | Formas de realizar el relleno | 269 |
| 6.1.2.1.1 | ALDEP | 269 |
| 6.1.2.1.2 | Curvas de relleno del Espacio - SFC | 272 |
| 6.1.2.1.3 | Definición de la técnica de colocación empleada. SFC y sus reglas | 274 |
| 6.1.2.2 | Estructura de Bandas | 277 |
| 6.1.2.2.1 | Número de bandas (n_b) | 279 |
| 6.1.2.2.2 | Ancho de Banda (b_i) | 280 |
| 6.1.2.2.3 | Secuencia de bandas | 283 |
| 6.1.2.3 | Secuencia de colocación empleada | 284 |
| 6.1.3 | Codificación de las soluciones | 285 |
| 6.2 | Generación de soluciones | 286 |
| 6.2.1 | Espacio de soluciones - Vecindad de una solución | 286 |
| 6.2.2 | Mecanismos de generación | 287 |
| 6.2.2.1 | Intercambio de actividades | 287 |
| 6.2.2.2 | Intercambio de bandas | 289 |
| 6.2.2.3 | Agregación de bandas | 290 |
| 6.2.2.4 | Expansión de bandas | 291 |
| 6.2.3 | Tamaño de la vecindad | 293 |
| 6.3 | Algoritmo de optimización empleado | 296 |
| 6.3.1 | Formulación del problema | 296 |
| 6.3.2 | Estructura de un algoritmo Simulated Annealing monoobjetivo | 297 |
| 6.3.2.1 | Modelo matemático del algoritmo | 300 |
| 6.3.2.2 | Implementación del algoritmo | 302 |
| 6.3.2.2.1 | Cálculo de la temperatura inicial | 302 |

| | | |
|------------|---|------------|
| 6.3.2.2.2 | Temperatura final (criterio de congelación) | 303 |
| 6.3.2.2.3 | Condición de equilibrio (Longitud de la cadena de Markov) | 303 |
| 6.3.2.2.4 | Lev de evolución de la temperatura | 304 |
| 6.3.3 | Algoritmo Annealing Multiobjetivo..... | 305 |
| 6.3.3.1 | Temperatura inicial del algoritmo | 308 |
| 6.3.3.2 | Esquema de enfriamiento | 310 |
| 6.3.3.3 | Condición de equilibrio en un escalón de temperatura | 311 |
| 6.3.3.4 | Criterio de congelación..... | 312 |
| 6.3.3.5 | Criterio de estabilización | 313 |
| 6.4 | Mecánica del proceso de optimización | 314 |
| 6.4.1 | Experimentos concatenados..... | 314 |
| 6.4.2 | Experimentos independientes | 314 |
| 6.4.2.1 | Criterio de parada del proceso de optimización..... | 315 |
| 6.4.2.2 | Depuración de la frontera de Pareto..... | 315 |
| 7 | PLAN EXPERIMENTAL. RESULTADOS OBTENIDOS | 317 |
| 7.1 | El problema de Armour y Buffa de 20 actividades. AB20..... | 319 |
| 7.2 | Soluciones históricas del problema..... | 323 |
| 7.2.1 | Modelo geométrico discreto..... | 323 |
| 7.2.2 | Modelo geométrico continuo | 327 |
| 7.2.3 | Fronteras de Pareto bicriterio del problema | 333 |
| 7.2.3.1 | Indicadores de configuración | 333 |
| 7.2.3.2 | Indicadores de actividad..... | 335 |
| 7.2.4 | Frontera de Pareto Coste - Circulación - Forma Media Ponderada | 337 |
| 7.3 | Evaluación del potencial del modelo geométrico empleado | 338 |
| 7.3.1 | Indicadores de configuración..... | 339 |
| 7.3.2 | Indicadores de actividad | 342 |
| 7.4 | Plan experimental y soluciones obtenidas | 344 |
| 7.4.1 | Obtención de Fronteras de Pareto Bicriterio | 345 |
| 7.4.1.1 | Frontera Coste-Circulación | 345 |
| 7.4.1.2 | Frontera Coste-Forma Media Ponderada..... | 349 |
| 7.4.1.3 | Frontera Coste-SRF..... | 353 |
| 7.4.1.4 | Frontera Coste-Forma Mínima | 357 |
| 7.4.1.5 | Frontera Coste-Robustez | 360 |
| 7.4.1.6 | Frontera Coste-Compacidad..... | 363 |
| 7.4.2 | Obtención de Frontera de Pareto Coste-Circulación-Forma Media Ponderada | 367 |
| 8 | CONCLUSIONES Y TRABAJO FUTURO..... | 373 |
| 8.1 | Conclusiones | 375 |
| 8.2 | Trabajos futuros | 379 |
| 9 | BIBLIOGRAFÍA | 381 |

ÍNDICE DE FIGURAS

| | |
|---|----|
| FIGURA 1.2.1 DISTRIBUCIÓN POR POSICIÓN FIJA (TOMADA DE WWW.NAVALGIJON.ES)..... | 9 |
| FIGURA 1.2.2 DISTRIBUCIÓN POR SECCIONES..... | 10 |
| FIGURA 1.2.3 DISTRIBUCIÓN EN PLANTA EN CADENA..... | 10 |
| FIGURA 1.2.4 CÉLULA DE FABRICACIÓN FLEXIBLE (IZDA.) Y SEMICÉLULA DE FABRICACIÓN (DER)..... | 11 |
| FIGURA 1.2.5 EJEMPLO DE DIAGRAMA ESQUEMÁTICO IDEAL DE BUFFA..... | 14 |
| FIGURA 1.2.6 DIAGRAMA DE BLOQUES (<i>BLOCK LAYOUT</i>) DE BUFFA..... | 14 |
| FIGURA 1.2.7 ESQUEMA DE ETAPAS DE LA METODOLOGÍA SLP (MUTHER 1968)..... | 18 |
| FIGURA 1.2.8 ANÁLISIS DE GRÁFICOS P-Q Y DISTRIBUCIONES BÁSICAS ASOCIADAS..... | 19 |
| FIGURA 1.2.9 HERRAMIENTAS PARA EL ANÁLISIS DEL RECORRIDO (MUTHER 1981)..... | 20 |
| FIGURA 1.2.10 EJEMPLO DE TABLA RELACIONAL DE ACTIVIDADES..... | 21 |
| FIGURA 1.2.11 EJEMPLO DE DIAGRAMA RELACIONAL DE ACTIVIDADES (IZDA.) Y DIAGRAMA RELACIONAL DE RECORRIDOS (DER.)..... | 22 |
| FIGURA 1.2.12 EJEMPLO DE DIAGRAMA RELACIONAL DE ESPACIOS..... | 23 |
| FIGURA 1.2.13 CLASIFICACIÓN DE LOS MÉTODOS DE GENERACIÓN DE LAYOUTS..... | 26 |
| FIGURA 1.2.14 HEURÍSTICAS PROPIAS DEL PROBLEMA DE DISTRIBUCIÓN EN PLANTA..... | 28 |
| FIGURA 1.2.15 ESTRATEGIAS DE DIVERSIFICACIÓN/INTENSIFICACIÓN SOBRE EL ESPACIO DE SOLUCIONES..... | 31 |
| FIGURA 1.2.16 CLASIFICACIÓN DE LAS METAHEURÍSTICAS, A PARTIR DE (BLUM Y ROLI 2003)..... | 31 |
| FIGURA 1.2.17 CLASIFICACIÓN DE METAHEURÍSTICAS DE (MELIAN, MORENO PÉREZ Y MORENO VEGA 2003)..... | 33 |
| FIGURA 2.1.1 CLASIFICACIÓN DE LOS MODELOS DE REPRESENTACIÓN ESPACIAL..... | 38 |
| FIGURA 2.1.2 REPRESENTACIONES DE DIAGRAMAS DE RELACIÓN..... | 39 |
| FIGURA 2.1.3 GRAFO Y SUBGRAFOS..... | 40 |
| FIGURA 2.1.4 EJEMPLO DE PLANARIDAD DE UN GRAFO..... | 41 |
| FIGURA 2.1.5 INCUMPLIMIENTO RELACIONAL CONSECUENCIA DE LA PLANARIDAD..... | 42 |
| FIGURA 2.1.6 GRAFO DUAL (CONTERO GONZALEZ 1995)..... | 42 |
| FIGURA 2.1.7 ÁRBOL DE EXPANSIÓN MAXIMAL..... | 43 |
| FIGURA 2.1.8 TRANSFORMACIÓN EN UN G.P.P.M.(SANTAMARINA 1995)..... | 44 |
| FIGURA 2.1.9 ARREGLO UNIDIMENSIONAL (SRLP)..... | 45 |
| FIGURA 2.1.10 CLASIFICACIÓN DE LOS MODELOS GEOMÉTRICOS EN 2D..... | 46 |
| FIGURA 2.1.11 REPRESENTACIÓN DE UN MODELO DISCRETO..... | 47 |
| FIGURA 2.1.12 DISTINTAS TÉCNICAS DE COLOCACIÓN DE ALDEP..... | 50 |
| FIGURA 2.1.13 RUTINA DE COLOCACIÓN EN SPIRAL DE PLANET (APPLE Y DEISENROTH 1972)..... | 50 |
| FIGURA 2.1.14 EJEMPLO DE SFC, ADAPTADO DE (BOZER, MELLER Y ERLEBACHER 1994)..... | 51 |
| FIGURA 2.1.15 SFC GENERADA MEDIANTE EL MÉTODO SUGERIDO EN (BOZER, MELLER Y ERLEBACHER 1994)..... | 51 |
| FIGURA 2.1.16 CONFIGURACIÓN DE UNA SOLUCIÓN CON ABSMODEL1 (HERAGU 1997)..... | 52 |
| FIGURA 2.1.17 CARACTERÍSTICAS FUNDAMENTALES DEL ABSMODEL2 (HERAGU 1997)..... | 53 |
| FIGURA 2.1.18 CARACTERÍSTICAS FUNDAMENTALES DEL ABSMODEL3 (HERAGU 1997)..... | 53 |
| FIGURA 2.1.19 DESCOMPOSICIÓN EN SUBACTIVIDADES, DE (BARBOSA-PÓVOA, MATEUS Y NOVAIS 2001)..... | 55 |
| FIGURA 2.1.20 EJEMPLO DE SOLUCIÓN DE (BARBOSA-PÓVOA, MATEUS Y NOVAIS 2001)..... | 55 |
| FIGURA 2.1.21 GEOMETRÍA DE ÁRBOLES DE CORTE..... | 56 |
| FIGURA 2.1.22 DENDOGRAMA, ADAPTADO DE (SANTAMARINA 1995)..... | 58 |
| FIGURA 2.1.23 REPRESENTACIÓN DE UN ÁRBOL DE CORTE..... | 58 |
| FIGURA 2.1.24 APLICACIÓN DE LOS OPERADORES DE CORTE SOBRE DOS ACTIVIDADES..... | 59 |
| FIGURA 2.1.25 APLICACIÓN DE UN OPERADOR SOBRE DOS CONJUNTOS DE ACTIVIDADES..... | 59 |
| FIGURA 2.1.26 REPRESENTACIÓN DE UNA SOLUCIÓN MEDIANTE ÁRBOLES DE CORTE..... | 59 |
| FIGURA 2.1.27 MODELO MULTI-BAY..... | 60 |
| FIGURA 2.1.28 REPRESENTACIÓN DE UNA SOLUCIÓN DE TATE Y SMITH..... | 61 |
| FIGURA 2.1.29 MÉTODOS A, B Y C DE (KIM Y KIM 1998)..... | 62 |
| FIGURA 2.1.30 FASE 1 DE LA METODOLOGÍA NLT, DE (ANJOS Y VANELLI 2006)..... | 65 |
| FIGURA 2.1.31 EFECTO ATRACTOR DE LA FUNCIÓN OBJETIVO..... | 66 |
| FIGURA 2.1.32 TRANSFORMACIÓN DE SOLUCIÓN EN LAYOUT DE BLOQUES, DE (ANJOS Y VANELLI 2006)..... | 67 |
| FIGURA 2.1.33 DISTRIBUCIÓN DE UN PROBLEMA MFLP DE DOS PLANTAS..... | 68 |
| FIGURA 2.1.34 USO DE SFC PARA CONSTRUIR LA DISTRIBUCIÓN EN CADA PLANTA (BOZER, MELLER Y ERLEBACHER 1994)..... | 71 |
| FIGURA 2.1.35 COLOCACIÓN DE LAS ACTIVIDADES EN LA PLANTA MEDIANTE SFC..... | 72 |
| FIGURA 2.1.36 DISTRIBUCIÓN EN DOS PISOS (KOCHHAR Y HERAGU 1998)..... | 72 |
| FIGURA 2.1.37 DISTRIBUCIÓN DE TRES PLANTAS EMPLEANDO EL OPERADOR "D" (MATSUZAKI, IROHARA Y YOSHIMOTO 1999)..... | 73 |
| FIGURA 2.1.38 DISTRIBUCIÓN EN UNA PLANTA ENTORNO AL ASCENSOR (LIN Y CHANG 2000)..... | 73 |
| FIGURA 2.1.39 ÁREAS DE TRABAJO ACCESIBLES EN (CHANG, LIN Y LIN 2006)..... | 74 |

| | |
|---|-----|
| FIGURA 2.1.40 SOLUCIÓN AL EJEMPLO 3 PARA EL “PROCESS PLANT LAYOUT” EN (PATSIATZIS Y PAPAGEORGIOU 2002)..... | 74 |
| FIGURA 2.1.41 ENTRADA Y SALIDA DE UNA ACTIVIDAD EN 3D. | 76 |
| FIGURA 2.2.1 CLASIFICACIÓN DE LAS MÉTRICAS DE LA DISTANCIA. | 77 |
| FIGURA 2.2.2 TOPOLOGÍA DE LAS MÉTRICAS MINKOWSKI. | 80 |
| FIGURA 2.2.3 DISTANCIA POR CONTORNO LATERAL. | 81 |
| FIGURA 2.2.4 EJEMPLO DE APLICACIÓN DE MÉTRICA EDIST. | 82 |
| FIGURA 3.1.1 OBJETIVOS-PRINCIPIOS-INDICADORES..... | 86 |
| FIGURA 3.1.2 RELACIÓN ENTRE OBJETIVOS Y PRINCIPIOS ENUNCIADOS EN (MUTHER 1955). | 94 |
| FIGURA 3.2.1 CLASIFICACIÓN DE LOS INDICADORES APLICADOS AL FLP. | 95 |
| FIGURA 3.2.2 FACTORES PARA CALCULAR FLF (RAMAN, NAGALINGAM Y LIN 2009). | 98 |
| FIGURA 3.2.3 INDICADORES DE (VAN CAMP, CARTER Y VANELLI 1991)..... | 101 |
| FIGURA 3.2.4 CIRCULACIÓN EN UNA DETERMINADA CONFIGURACIÓN. | 107 |
| FIGURA 3.2.5 DEGENERACIONES FORMALES..... | 108 |
| FIGURA 3.2.6 ALGUNAS SOLUCIONES ÓPTIMAS DE (TATE Y SMITH 1995). | 109 |
| FIGURA 3.2.7 INDICADORES GEOMÉTRICOS EN EL PROBLEMA DE DISTRIBUCIÓN EN PLANTA..... | 109 |
| FIGURA 3.2.8 DIFERENTES VALORES DE Ω_i^{-1} PARA UNA ACTIVIDAD DE 9 CASILLAS. | 111 |
| FIGURA 3.2.9 VALORES MÍNIMOS DE Ω_i^{-1} PARA ACTIVIDADES DE DIFERENTE ÁREA. | 112 |
| FIGURA 3.2.10 VARIACIÓN DEL INDICADOR Ω^{-1} MÍNIMO Y MÁXIMO CON EL NÚMERO DE CASILLAS. | 113 |
| FIGURA 3.2.11 EVOLUCIÓN DEL INDICADOR $\tilde{\Omega}^{-1}(n)$ PARA $\Omega^{-1}=0.5$ | 113 |
| FIGURA 3.2.12 EVALUACIÓN DEL INDICADOR δ PARA VARIAS ACTIVIDADES DE N=9..... | 114 |
| FIGURA 3.2.13 EVALUACIÓN DEL INDICADOR δ EN ACTIVIDADES CON ROTURA. | 114 |
| FIGURA 3.2.14 CÁLCULO DE LA COMPACIDAD DE LA ACTIVIDAD I-ÉSIMA. | 116 |
| FIGURA 3.2.15 DIFERENTES VALORES DE COMPACIDAD PARA UNA ACTIVIDAD DE 9 CASILLAS. | 117 |
| FIGURA 3.2.16 CONFIGURACIONES CON $\gamma_i = 1$ | 117 |
| FIGURA 3.2.17 EVOLUCIÓN DEL INDICADOR COMPACIDAD CON EL ÁREA. | 118 |
| FIGURA 3.2.18 ROBUSTEZ DE LA ACTIVIDAD I-ÉSIMA..... | 119 |
| FIGURA 3.2.19 DIFERENTES VALORES DE ROBUSTEZ PARA UNA ACTIVIDAD DE 9 CASILLAS. | 120 |
| FIGURA 3.2.20 CONFIGURACIONES CON $\rho_i=1$ | 120 |
| FIGURA 3.2.21 DETERMINACIÓN DEL INDICADOR FORMA DE UNA ACTIVIDAD. | 121 |
| FIGURA 3.2.22 DIFERENTES VALORES DE FORMA PARA UNA ACTIVIDAD DE 9 CASILLAS..... | 122 |
| FIGURA 3.2.23 CONFIGURACIONES CON $\phi_x=0.4$ Y $\phi_y=0.36$ | 122 |
| FIGURA 3.2.24 VALORES DE FORMA MODIFICADA CON UN VALOR DE K=2. | 123 |
| FIGURA 3.2.25 EVOLUCIÓN DEL INDICADOR FORMA ϕ CON EL ÁREA. | 123 |
| FIGURA 3.2.26 CÁLCULO DEL RATIO K DE UNA ACTIVIDAD. | 124 |
| FIGURA 3.2.27 DIFERENTES VALORES DEL RATIO K PARA UNA ACTIVIDAD DE 9 CASILLAS..... | 124 |
| FIGURA 3.2.28 FACTOR R_i DE LA ACTIVIDAD I-ÉSIMA. | 125 |
| FIGURA 3.2.29 DIFERENTES VALORES DE R_k PARA UNA ACTIVIDAD DE 9 CASILLAS..... | 126 |
| FIGURA 3.2.30 FACTOR R_k DE ACTIVIDADES CUADRADAS. | 126 |
| FIGURA 3.2.31 VALORES SIGNIFICATIVOS PARA UNA ACTIVIDAD DE 9 CASILLAS. | 129 |
| FIGURA 3.2.32 DIFERENTES VALORES DE Ω_4 PARA UNA ACTIVIDAD DE 9 CASILLAS. | 129 |
| FIGURA 3.2.33 PLANTEAMIENTO CON RECINTO ESTRICTO (IZQ.) Y CON HOLSURA (DCHA.). | 130 |
| FIGURA 3.3.1 RELACIÓN OBJETIVOS-PRINCIPIOS-INDICADORES. | 133 |
| FIGURA 3.3.2 ACTIVIDAD CON POSIBLE PROBLEMA DE IMPLANTACIÓN..... | 136 |
| FIGURA 3.4.1 REPRESENTACIÓN DEL PASEO ALEATORIO COSTE-Nº ITERACIÓN. | 139 |
| FIGURA 3.4.2 RELACIÓN COSTE ENTRE CENTROIDES - CIRCULACIÓN. | 140 |
| FIGURA 3.4.3 RELACIÓN COSTE ENTRE CENTROIDES - COSTE EDIST. | 141 |
| FIGURA 3.4.4 CORRELACIÓN DEL INDICADOR DE FORMA Y EL FACTOR K. | 142 |
| FIGURA 3.4.5 CORRELACIÓN DE LA FMP CON LA KMP(i) Y LA $\rho MP(D)$ | 142 |
| FIGURA 3.4.6 CORRELACIÓN DE LA INERCIA CON LA IMP Y CON Ω^{-1} | 143 |
| FIGURA 3.4.7 CORRELACIÓN DE LA CMP CON LA COMPACIDAD. | 143 |
| FIGURA 3.4.8 RELACIÓN DE CMP Y COMPACIDAD CON LA ROBUSTEZ (AB) Y SRF (AR). | 144 |
| FIGURA 3.4.9 REPRESENTACIÓN DE SRF FRENTE AL RESTO DE INDICADORES. | 145 |
| FIGURA 3.4.10 REPRESENTACIÓN DE LA ROBUSTEZ FRENTE AL RESTO DE INDICADORES. | 146 |
| FIGURA 3.4.11 REPRESENTACIÓN DE LA COMPACIDAD FRENTE AL RESTO DE INDICADORES..... | 147 |
| FIGURA 3.4.12 REPRESENTACIÓN DEL INDICADOR DE FORMA FRENTE AL RESTO DE INDICADORES..... | 148 |
| FIGURA 3.4.13 REPRESENTACIÓN DE LA FORMA MEDIA PONDERADA FRENTE A LA INERCIA. | 148 |
| FIGURA 3.4.14 EL INDICADOR DE CIRCULACIÓN FRENTE AL RESTO DE LOS INDICADORES GEOMÉTRICOS. | 149 |

| | |
|---|-----|
| FIGURA 3.4.15 INDICADORES SELECCIONADOS PARA LA OPTIMIZACIÓN..... | 151 |
| FIGURA 4.1.1 LAS SOLUCIONES A-E SON ÓPTIMOS DE PARETO DEL CONJUNTO DE SOLUCIONES S..... | 157 |
| FIGURA 4.1.2 LA SOLUCIÓN B DOMINA AL CONJUNTO DE SOLUCIONES EN ROJO..... | 157 |
| FIGURA 4.1.3 CONJUNTO ÓPTIMO DE PARETO..... | 158 |
| FIGURA 4.1.4 REPRESENTACIÓN DE LA FRONTERA DE PARETO..... | 158 |
| FIGURA 4.2.1 CLASIFICACIÓN DE LOS MÉTODOS DE OPTIMIZACIÓN MULTIOBJETIVO..... | 159 |
| FIGURA 4.2.2 TÉCNICAS DE OPTIMIZACIÓN NO BASADAS EN PARETO..... | 159 |
| FIGURA 4.3.1 TÉCNICAS DE OPTIMIZACIÓN BASADAS EN PARETO..... | 166 |
| FIGURA 4.3.2 TÉCNICAS DE OPTIMIZACIÓN MOEA BASADAS EN PARETO..... | 167 |
| FIGURA 4.3.3 MECANISMO DEL DE/RAND/1/BIN (MEZURA-MONTES, REYES-SIERRA Y COELLO COELLO 2008)..... | 180 |
| FIGURA 4.4.1 TÉCNICAS DE OPTIMIZACIÓN MULTIOBJETIVO BASADAS EN SIMULATED ANNEALING..... | 184 |
| FIGURA 4.4.2 TRES VÍAS DIFERENTES DE ABORDAR EL PROBLEMA DE OPTIMIZACIÓN (KNOWLES Y CORNE 2004)..... | 185 |
| FIGURA 4.4.3 ILUSTRACIÓN GRÁFICA DE LA REGLA SL (CZYŻAK Y JASZKIEWICZ 1998)..... | 189 |
| FIGURA 4.4.4 SOLUCIONES MUTUAMENTE NO DOMINADAS..... | 191 |
| FIGURA 4.4.5 CALCULO DE LOS AJUSTES SEGÚN PDMOSA..... | 195 |
| FIGURA 4.4.6 EJEMPLO DEL CÁLCULO DE δE | 202 |
| FIGURA 5.0.1 NATURALEZA MULTICRITERIO DEL PROBLEMA DE LA DISTRIBUCIÓN EN PLANTA (SANTAMARINA 1995)..... | 210 |
| FIGURA 5.0.2 CLASIFICACIÓN DE (WAGHODEKAR Y SAHU 1986)..... | 210 |
| FIGURA 5.0.3 PUBLICACIONES DEL PROBLEMA FLP MULTIOBJETIVO EN REVISTAS INTERNACIONALES..... | 211 |
| FIGURA 5.1.1 CLASIFICACIÓN DE WAGHODEKAR Y SAHU..... | 212 |
| FIGURA 5.1.2 DISTRIBUCIÓN DE ARTÍCULOS SEGÚN CLASIFICACIÓN DE WAGHODEKAR..... | 213 |
| FIGURA 5.1.3 CLASIFICACIÓN DE MALAKOOTI..... | 215 |
| FIGURA 5.1.4 DISTRIBUCIÓN DE ARTÍCULOS SEGÚN CLASIFICACIÓN DE (MALAKOOTI 1989)..... | 215 |
| FIGURA 5.1.5 CLASIFICACIÓN PROPUESTA..... | 218 |
| FIGURA 5.1.6 DISTRIBUCIÓN DE ARTÍCULOS SEGÚN CLASIFICACIÓN PROPIA..... | 218 |
| FIGURA 5.2.1 ESQUEMA DE LA METODOLOGÍA (YANG Y KUO 2003)..... | 221 |
| FIGURA 5.3.1 ACTIVIDADES, LOCALIZACIONES Y ASIGNACIÓN DE ACTIVIDAD A LOCALIZACIÓN PARA N=5..... | 222 |
| FIGURA 5.3.2 DISTRIBUCIÓN DE PUBLICACIONES DE OPTIMIZACIÓN DE SOLUCIONES..... | 224 |
| FIGURA 5.3.3 MÉTODOS BASADOS EN FUNCIONES AGREGADAS..... | 225 |
| FIGURA 5.3.4 CONSIDERACIONES DE FRONTERA PARA ROSENBLATT Y DUTTA..... | 228 |
| FIGURA 5.3.5 CARIZ DE LOS OBJETIVOS EN (KHARE, KHARE Y NEEMA 1988)..... | 234 |
| FIGURA 5.3.6 FUNCIONES DE VALOR MARGINAL PARA EL EJEMPLO DE (SARIN ET AL. 1992)..... | 236 |
| FIGURA 5.3.7 HEURÍSTICA DE 5 PASOS DE (CHEN Y SHA 2005)..... | 242 |
| FIGURA 5.3.8 MÉTODOS BASADOS EN FRONTERA DE PARETO..... | 253 |
| FIGURA 5.3.9 PUNTO DOMINADO CON LA 2ª REGLA DE DOMINACIÓN DE ROSENBLATT..... | 254 |
| FIGURA 5.3.10 RIESGO DE NO GENERACIÓN DE SOLUCIONES VÁLIDAS, DE (MALAKOOTI 1989)..... | 255 |
| FIGURA 6.1.1 ASPECTOS A TENER EN CUENTA EN LA CONSTRUCCIÓN DE UNA SOLUCIÓN..... | 264 |
| FIGURA 6.1.2 DOS FORMAS DE ORIENTAR EL RECINTO R=1.5 (i) Y R=0.67 (d)..... | 266 |
| FIGURA 6.1.3 CONFIGURACIÓN DE BANDAS EN DOS RECINTOS CON R=1.5 Y R=0.67..... | 266 |
| FIGURA 6.1.4 PASEO ALEATORIO CON TAMAÑO DE RECINTO VARIABLE..... | 267 |
| FIGURA 6.1.5 RELLENO MEDIANTE DISTINTAS VARIANTES DE ALDEP..... | 269 |
| FIGURA 6.1.6 RELLENO ALDEP OSCILATORIO XY (ANCHO DE BANDA IGUAL)..... | 270 |
| FIGURA 6.1.7 RELLENO OSCILATORIO DE BANDAS DESIGUALES (ISLIER 1998)..... | 270 |
| FIGURA 6.1.8 PROBLEMAS CON ALDEP Y EL NÚMERO DE CELDAS N_H | 270 |
| FIGURA 6.1.9 PROBLEMAS CON ALDEP, EL NÚMERO DE CELDAS N_H Y EL NÚMERO DE BANDAS N_B | 271 |
| FIGURA 6.1.10 EJEMPLO DE SFC, ADAPTADO DE (BOZER, MELLER Y ERLEBACHER 1994)..... | 272 |
| FIGURA 6.1.11 SFC GENERADA MEDIANTE EL MÉTODO SUGERIDO EN (BOZER, MELLER Y ERLEBACHER 1994)..... | 272 |
| FIGURA 6.1.12 PROCEDIMIENTO DE WANG PARA SFC..... | 273 |
| FIGURA 6.1.13 DEFINICIÓN DE GIRO DE LA SFC..... | 275 |
| FIGURA 6.1.14 ARRANQUE DE LA SFC PARA UN CASO DE N_H PAR SIN ROTURA Y CON ROTURA..... | 276 |
| FIGURA 6.1.15 DEFINICIÓN DE REGLAS DE TRANSICIÓN ENTRE BANDAS..... | 277 |
| FIGURA 6.1.16 SOLUCIÓN 1 DE (WANG, HU Y KU 2005), CON 4 BANDAS..... | 278 |
| FIGURA 6.1.17 VARIABLES EN LA ESTRUCTURA DE BANDAS..... | 278 |
| FIGURA 6.1.18 DOS ITERACIONES SUCEATIVAS EN UNA ESTRATEGIA CON $N_B=CTE$ Y $B_i=CTE$ | 281 |
| FIGURA 6.1.19 SOLUCIÓN CON UN ANCHO DE BANDA VARIABLE $B_i \neq CTE$ | 282 |
| FIGURA 6.1.20 SECUENCIA DE BANDAS DINÁMICA..... | 284 |
| FIGURA 6.1.21 SOLUCIÓN 1 DE LA FRONTERA COSTE-CIRCULACIÓN, CON UN VALOR NULO DE CIRCULACIÓN..... | 285 |
| FIGURA 6.2.1 VECONDAD DE UNA SOLUCIÓN..... | 286 |

| | |
|---|-----|
| FIGURA 6.2.2 BÚSQUEDA POR ENTORNOS VARIABLES. TRANSICIÓN A SOLUCIÓN VECINA. | 287 |
| FIGURA 6.2.3 SOLUCIÓN \vec{a}_{k+1} EN LA VECINDAD DE LA CONFIGURACIÓN \vec{a}_k | 288 |
| FIGURA 6.2.4 SOLUCIÓN \vec{b}_{k+1} EN LA VECINDAD DE LA CONFIGURACIÓN \vec{b}_k | 291 |
| FIGURA 6.2.5 SOLUCIÓN \vec{b}_{k+1} EN LA VECINDAD DE LA CONFIGURACIÓN \vec{b}_k | 292 |
| FIGURA 6.2.6 VARIACIÓN DEL TAMAÑO DE LA VECINDAD PARA EL PROBLEMA AB20. | 293 |
| FIGURA 6.2.7 PORCENTAJES DE TAMAÑO DE VECINDAD SEGÚN DIFERENTES MECANISMOS DE GENERACIÓN. | 293 |
| FIGURA 6.2.8 PORCENTAJES DE TAMAÑO DE VECINDAD SEGÚN DIFERENTES MECANISMOS DE GENERACIÓN. | 294 |
| FIGURA 6.2.9 DLS PARA UNA "RULETA DE TRANSICIÓN" CON DISTRIBUCIÓN PROPORCIONAL. | 295 |
| FIGURA 6.3.1 SA MONOBJETIVO. | 298 |
| FIGURA 6.3.2 SA MONOBJETIVO DETALLADO. | 299 |
| FIGURA 6.3.3 ALGORITMO ANNEALING MULTI OBJETIVO PROPUESTO..... | 305 |
| FIGURA 6.3.4 DETERMINACIÓN DEL COEFICIENTE DE ENFRIAMIENTO DE (GONZALEZ 2005). | 310 |
| FIGURA 6.3.5 EJEMPLO DE ESQUEMA DE ENFRIAMIENTO. | 310 |
| FIGURA 6.4.1 ESQUEMA DE EXPERIMENTO CONCATENADO. | 314 |
| FIGURA 6.4.2 ESQUEMA DE EXPERIMENTOS INDEPENDIENTES..... | 315 |
| FIGURA 7.1.1 ÍNDICE DE COMPLEJIDAD (C_c) DE LOS PROBLEMAS. | 322 |
| FIGURA 7.2.1 SOLUCIÓN INICIAL DE (ARMOUR Y BUFFA 1963), AB00. | 323 |
| FIGURA 7.2.2 SOLUCIÓN FINAL DE (ARMOUR Y BUFFA 1963), AB01..... | 324 |
| FIGURA 7.2.3 SOLUCIÓN FINAL DE (BOZER, MELLER Y ERLEBACHER 1994), BOZ..... | 324 |
| FIGURA 7.2.4 MEJOR RESULTADO OBTENIDO EN (CONTERO GONZALEZ 1995), MC..... | 325 |
| FIGURA 7.2.5 SOLUCIÓN DE (WANG, HU Y KU 2005) PARA UN RECINTO R=1.5, MJW1..... | 326 |
| FIGURA 7.2.6 SOLUCIÓN DE (WANG, HU Y KU 2005) PARA UN RECINTO R=0.96, MJW2..... | 326 |
| FIGURA 7.2.7 SOLUCIÓN DE (GONZALEZ 2005) PARA EL BICRITERIO FORMA-COSTE, GON..... | 327 |
| FIGURA 7.2.8 SOLUCIÓN TS1 DE (TATE Y SMITH 1995) Y VALORES DE INDICADORES. | 328 |
| FIGURA 7.2.9 SOLUCIÓN TS2 DE (TATE Y SMITH 1995) Y VALORES DE INDICADORES..... | 328 |
| FIGURA 7.2.10 SOLUCIÓN TS3 DE (TATE Y SMITH 1995) Y VALORES DE INDICADORES. | 328 |
| FIGURA 7.2.11 SOLUCIÓN TS4 DE (TATE Y SMITH 1995) Y VALORES DE INDICADORES. | 329 |
| FIGURA 7.2.12 SOLUCIÓN TS5 DE (TATE Y SMITH 1995) Y VALORES DE INDICADORES. | 329 |
| FIGURA 7.2.13 SOLUCIÓN TS6 DE (TATE Y SMITH 1995) Y VALORES DE INDICADORES. | 329 |
| FIGURA 7.2.14 SOLUCIÓN MEL DE (MELLER Y GAU 1996) Y VALORES DE INDICADORES. | 330 |
| FIGURA 7.2.15 SOLUCIÓN K1 DE (KIM Y KIM 1998) Y VALORES DE INDICADORES. | 331 |
| FIGURA 7.2.16 SOLUCIÓN K2 DE (KIM Y KIM 1998) Y VALORES DE INDICADORES. | 331 |
| FIGURA 7.2.17 SOLUCIÓN K3 DE (KIM Y KIM 1998) Y VALORES DE INDICADORES. | 331 |
| FIGURA 7.2.18 SOLUCIÓN ANJ DE (ANJOS Y VANELLI 2006) Y VALORES DE INDICADORES. | 332 |
| FIGURA 7.2.19 FRONTERA DE PARETO "HISTÓRICA" PARA LOS CRITERIOS COSTE-CIRCULACIÓN. | 333 |
| FIGURA 7.2.20 FRONTERA DE PARETO "HISTÓRICA" PARA LOS CRITERIOS COSTE-FORMA MEDIA PONDERADA. | 334 |
| FIGURA 7.2.21 FRONTERA DE PARETO "HISTÓRICA" PARA LOS CRITERIOS COSTE-SRF. | 334 |
| FIGURA 7.2.22 FRONTERA DE PARETO "HISTÓRICA" PARA LOS CRITERIOS COSTE-FORMA MÍNIMA. | 335 |
| FIGURA 7.2.23 FRONTERA DE PARETO "HISTÓRICA" PARA LOS CRITERIOS COSTE-ROBUSTEZ MÍNIMA. | 336 |
| FIGURA 7.2.24 FRONTERA DE PARETO "HISTÓRICA" PARA LOS CRITERIOS COSTE-COMPACIDAD. | 336 |
| FIGURA 7.2.25 VALORES "HISTÓRICOS" DE LOS INDICADORES COSTE, CIRCULACIÓN Y FMP. | 337 |
| FIGURA 7.3.1 RESULTADOS DE PASEO ALEATORIO PARA EL BICRITERIO COSTE - CIRCULACIÓN. | 339 |
| FIGURA 7.3.2 RESULTADOS DE PASEO ALEATORIO PARA EL BICRITERIO COSTE - FMP. | 340 |
| FIGURA 7.3.3 RESULTADOS DE PASEO ALEATORIO PARA EL BICRITERIO COSTE - SRF..... | 341 |
| FIGURA 7.3.4 RESULTADOS DE PASEO ALEATORIO PARA EL BICRITERIO COSTE - FORMA MÍNIMA. | 342 |
| FIGURA 7.3.5 RESULTADOS DE PASEO ALEATORIO PARA EL BICRITERIO COSTE - ROBUSTEZ..... | 343 |
| FIGURA 7.3.6 RESULTADOS DE PASEO ALEATORIO PARA EL BICRITERIO COSTE - COMPACIDAD. | 343 |
| FIGURA 7.4.1 EVOLUCIÓN DE LA FRONTERA CTC-CIRCULACIÓN. | 345 |
| FIGURA 7.4.2 FRONTERA DE PARETO DISCRETA DEL BICRITERIO COSTE-CIRCULACIÓN. | 346 |
| FIGURA 7.4.3 NUEVA FRONTERA DE PARETO DEL BICRITERIO COSTE-CIRCULACIÓN. | 347 |
| FIGURA 7.4.4 SOLUCIÓN 1 DE LA FRONTERA COSTE-CIRCULACIÓN, CON UN VALOR NULO DE CIRCULACIÓN..... | 348 |
| FIGURA 7.4.5 SOLUCIÓN 8 DE LA FRONTERA COSTE-CIRCULACIÓN. | 348 |
| FIGURA 7.4.6 EVOLUCIÓN DE LA FRONTERA DE PARETO COSTE-FMP. | 349 |
| FIGURA 7.4.7 FRONTERA DE PARETO COSTE-FMP OBTENIDA. | 350 |
| FIGURA 7.4.8 SOLUCIÓN DE LA FRONTERA DE PARETO CON ELEVADO VALOR DE FMP. | 350 |
| FIGURA 7.4.9 NUEVA FRONTERA DE PARETO DEL BICRITERIO COSTE-FORMA MEDIA PONDERADA. | 351 |
| FIGURA 7.4.10 SOLUCIÓN APORTADA Nº 1 A LA FRONTERA COSTE-FMP. | 352 |

| | |
|---|-----|
| FIGURA 7.4.11 EVOLUCIÓN DE LA FRONTERA DE PARETO COSTE-SRF | 353 |
| FIGURA 7.4.12 FRONTERA DE PARETO COSTE-SRF DISCRETA. | 354 |
| FIGURA 7.4.13 NUEVA FRONTERA DE PARETO DEL BICRITERIO COSTE-SRF..... | 354 |
| FIGURA 7.4.14 SOLUCIÓN APORTADA Nº 5 A LA FRONTERA COSTE-SRF. | 356 |
| FIGURA 7.4.15 SOLUCIÓN APORTADA Nº 20 A LA FRONTERA COSTE-SRF. | 356 |
| FIGURA 7.4.16 EVOLUCIÓN DE LA FRONTERA DE PARETO COSTE-FORMA MÍNIMA. | 357 |
| FIGURA 7.4.17 SOLUCIÓN DE LA FRONTERA CON MEJOR FORMA. | 358 |
| FIGURA 7.4.18 NUEVA FRONTERA DE PARETO DISCRETA PARA EL BICRITERIO COSTE-FORMA MÍNIMA. | 358 |
| FIGURA 7.4.19 NUEVA FRONTERA DE PARETO DEL BICRITERIO COSTE-FORMA MÍNIMA. | 359 |
| FIGURA 7.4.20 SOLUCIÓN APORTADA Nº 1 A LA FRONTERA COSTE-FORMA MÍNIMA..... | 360 |
| FIGURA 7.4.21 EVOLUCIÓN DE LA FRONTERA DE PARETO COSTE-ROBUSTEZ MÍNIMA..... | 360 |
| FIGURA 7.4.22 SOLUCIÓN OBTENIDA CON MAYOR ROBUSTEZ MÍNIMA..... | 361 |
| FIGURA 7.4.23 EVOLUCIÓN DE LA FRONTERA DE PARETO COSTE-ROBUSTEZ MÍNIMA..... | 361 |
| FIGURA 7.4.24 NUEVA FRONTERA DE PARETO DEL BICRITERIO COSTE-ROBUSTEZ MÍNIMA. | 362 |
| FIGURA 7.4.25 SOLUCIÓN APORTADA Nº 4 A LA FRONTERA COSTE-ROBUSTEZ MÍNIMA. | 363 |
| FIGURA 7.4.26 EVOLUCIÓN DE LA FRONTERA DE PARETO COSTE-COMPACIDAD. | 363 |
| FIGURA 7.4.27 NUEVA FRONTERA DE PARETO DEL BICRITERIO COSTE-COMPACIDAD MÁXIMA. | 364 |
| FIGURA 7.4.28 SOLUCIÓN APORTADA Nº 3 A LA FRONTERA COSTE-COMPACIDAD MÁXIMA..... | 365 |
| FIGURA 7.4.29 SOLUCIÓN DE LA FRONTERA COSTE-COMPACIDAD MÁXIMA CON MAYOR COMPACIDAD. | 366 |
| FIGURA 7.4.30 FRONTERA DE PARETO CTC-FORMA MEDIA PONDERADA-CIRCULACIÓN. | 368 |
| FIGURA 7.4.31 PROYECCIÓN DE LA FRONTERA DE PARETO EN BICRITERIOS. | 368 |
| FIGURA 7.4.32 PROYECCIÓN 2D Y FRONTERA BICRITERIO COSTE-CIRCULACIÓN..... | 369 |
| FIGURA 7.4.33 PROYECCIÓN 2D Y FRONTERA BICRITERIO COSTE-FORMA MEDIA PONDERADA..... | 370 |
| FIGURA 7.4.34 PROYECCIÓN 2D Y FRONTERA BICRITERIO CIRCULACIÓN-FORMA MEDIA PONDERADA. | 371 |
| FIGURA 7.4.35 SOLUCIÓN CON CIRCULACIÓN NULA. | 371 |
| FIGURA 8.1.1 ESQUEMA DE INDICADORES DEL "BLOCK LAYOUT"..... | 375 |
| FIGURA 8.1.2 RELACIÓN OBJETIVOS-PRINCIPIOS-INDICADORES..... | 375 |
| FIGURA 8.1.3 INDICADOR DE CIRCULACIÓN PROPUESTO..... | 376 |
| FIGURA 8.1.4 EJEMPLO DE CÁLCULO DE MÉTRICA EDIST. | 376 |
| FIGURA 8.1.5 ESQUEMA DE FUNCIONAMIENTO DEL ALGORITMO PROPUESTO..... | 377 |
| FIGURA 8.1.6 UNA DE LAS FRONTERAS DE PARETO OBTENIDAS. | 377 |
| FIGURA 8.1.7 FRONTERA DE PARETO 3D OBTENIDA..... | 378 |

ÍNDICE DE TABLAS

| | |
|---|-----|
| TABLA 1.2.1 MODOS DE PRODUCCIÓN SEGÚN EL MOVIMIENTO DE LOS MEDIOS Y EJEMPLOS..... | 8 |
| TABLA 1.2.2 CARACTERÍSTICAS DE LOS TIPOS BÁSICOS DE DISTRIBUCIÓN EN PLANTA..... | 12 |
| TABLA 2.1.1 OPERADORES DE CORTE..... | 58 |
| TABLA 2.1.2 CLASIFICACIÓN DE LAS METODOLOGÍAS APLICADAS MFLP EN FUNCIÓN DE LAS FASES..... | 69 |
| TABLA 3.2.1 VALORES DE TRANSFORMACIÓN PARA CR_{ij} | 96 |
| TABLA 3.2.2 FACTOR DE ADYACENCIA..... | 99 |
| TABLA 3.4.1 DATOS ESTADÍSTICOS DE INDICADORES OBTENIDOS MEDIANTE PASEO ALEATORIO (1)..... | 139 |
| TABLA 3.4.2 DATOS ESTADÍSTICOS DE INDICADORES OBTENIDOS MEDIANTE PASEO ALEATORIO (2)..... | 139 |
| TABLA 3.4.3 INDICADORES CUANTITATIVOS RECOPIADOS DE LA BIBLIOGRAFÍA..... | 141 |
| TABLA 3.4.4 INDICADORES GEOMÉTRICOS REDUCIDOS..... | 144 |
| TABLA 5.3.1 MATRIZ DE PREFERENCIA DE PROXIMIDAD (P_R), BAJO EL CRITERIO SEGURIDAD..... | 238 |
| TABLA 5.3.2 EJEMPLO DE MATRIZ DE ÍNDICE DE CERCANÍA (R_{ij}) ENTRE ACTIVIDADES ($N=4$)..... | 239 |
| TABLA 5.3.3 VALORES DE TRANSFORMACIÓN PARA R_{ij} | 247 |
| TABLA 5.3.4 SOLUCIONES DE (SAHIN Y TÜRKBEY 2009)..... | 260 |
| TABLA 6.1.1 CASOS QUE PROVOCAN ROTURA..... | 271 |
| TABLA 6.1.2 DEFINICIÓN DE VARIABLES DE BANDAS - SECUENCIA DE BANDAS..... | 283 |
| TABLA 6.2.1 EXPERIMENTO CON DLS PARA OBTENER EL PORCENTAJE DE LOS MECANISMOS DE GENERACIÓN..... | 295 |
| TABLA 6.3.1 VALORES DE T_i PARA 100 LANZAMIENTOS DEL ALGORITMO..... | 309 |
| TABLA 6.3.2 TAMAÑOS DE ESCALÓN EN EL ALGORITMO MULTIOBJETIVO EMPLEADO..... | 312 |
| TABLA 7.1.1 SUPERFICIE DE CADA UNA DE LAS 20 ACTIVIDADES DEL PROBLEMA AB20..... | 319 |
| TABLA 7.1.2 MATRIZ DE FLUJOS ENTRE ACTIVIDADES W_{ij} (\$/AÑO·100 PIES)..... | 320 |
| TABLA 7.4.1 SOLUCIONES APORTADAS A LA FRONTERA DE PARETO COSTE-CIRCULACIÓN..... | 347 |
| TABLA 7.4.2 SOLUCIONES APORTADAS A LA FRONTERA DE PARETO COSTE-FMP..... | 351 |
| TABLA 7.4.3 SOLUCIONES APORTADAS A LA FRONTERA DE PARETO COSTE-SRF..... | 355 |
| TABLA 7.4.4 SOLUCIONES APORTADAS A LA FRONTERA DE PARETO COSTE-FORMA MÍNIMA..... | 359 |
| TABLA 7.4.5 SOLUCIONES APORTADAS A LA FRONTERA DE PARETO COSTE-ROBUSTEZ MÍNIMA..... | 362 |
| TABLA 7.4.6 SOLUCIONES APORTADAS A LA FRONTERA DE PARETO COSTE-COMPACIDAD MÁXIMA..... | 365 |

1 INTRODUCCIÓN AL PROBLEMA

1.1 INTRODUCCIÓN Y OBJETIVOS

En un tiempo en el que la mayor parte de las decisiones empresariales van encaminadas a la reducción de costes, la correcta ordenación de las actividades que componen una planta industrial es una vía que debe ser explorada y explotada de una manera exhaustiva.

A mitad del siglo XX, tras la segunda guerra mundial, un grupo de ingenieros, encabezados por Muther comenzaron a investigar, estableciendo metodologías que permitieran encontrar una distribución en planta óptima para todas las industrias que proyectaban. El objetivo fundamental era conseguir un procedimiento estricto que considerara todos los aspectos que afectan a un correcto diseño, explotación y desmantelamiento de las plantas, sin que quedara descuidado ninguno de ellos. Dentro de estas metodologías propuestas, destaca el *Systematic Layout Problem* (SLP), propuesto en (Muther 1968), que desde su aparición se convirtió en referencia en el campo de la ingeniería de proyectos de plantas industriales.

A raíz de la aparición de esta metodología, aparecieron un gran número de investigaciones centradas en la resolución del *layout de bloques*, fase en la que se obtiene la posición relativa de las distintas actividades que conforman la planta, sin tener en cuenta los puntos de entrada y salida de materiales de cada una de ellas ni la existencia de pasillos. En los años 70 y 80 se establecen heurísticas específicas que orientan la búsqueda de soluciones óptimas para un problema que tiene una elevada complejidad y que es complicado abordar por métodos exactos cuando el número de actividades crece. La década de los 90 está marcada por el uso masivo de metaheurísticas para la resolución del problema, apareciendo algoritmos bioinspirados que resuelven el layout de bloques con efectividad.

Sin embargo muchas de las aportaciones realizadas en la resolución del problema adolecen de una falta de visión de conjunto del problema, puesto que centran la resolución del mismo desde un único objetivo: la reducción del coste de manutención. Parece claro que el coste es el objetivo más importante del problema, pero no el único, tal y como establece el propio Muther en la exposición de su metodología. Se puede considerar que la naturaleza del problema de distribución en planta, incluso en la fase del layout de bloques es claramente multiobjetivo, siendo este enfoque el camino a seguir en esta línea de investigación durante los próximos años.

Desde la aproximación realizada por (Rosenblatt 1979), numerosos autores se han acercado al problema desde un enfoque multiobjetivo, agregando varios criterios en una sola función objetivo que posteriormente se optimiza. La función objetivo aditiva o multiplicativa combina, en la mayor parte de los casos, el coste entre centros de gravedad (objetivo cuantitativo) y un criterio de cercanía (con un marcado carácter cualitativo), algo que en ocasiones puede producir falta de homogeneidad en las soluciones obtenidas.

A pesar de que algunos autores introducen el uso de otros indicadores distintos del coste y del índice de cercanía, no existe una recopilación de los mismos ni ningún estudio que determine el conjunto de indicadores suficientes, independientes y no congruentes que puedan ser utilizados en la resolución del *layout de bloques*. Tampoco se ha establecido en la bibliografía una relación directa entre los objetivos establecidos por los diferentes autores, los principios fundamentales del problema de distribución en planta fijados en (Muther 1968) y los distintos indicadores que se han empleado en el problema a lo largo de las últimas décadas.

En la última década, se han adoptado técnicas de optimización multiobjetivo basadas en fronteras de Pareto en la resolución del layout de bloques. Estas técnicas no utilizan una función objetivo, sino que trabajan con conjuntos de soluciones eficientes que van variando en el proceso de optimización, basado en una metaheurística concreta. Una vez conseguido el conjunto eficiente (frontera de Pareto) se pueden utilizar técnicas de jerarquización de soluciones (tipo AHP) para obtener la mejor solución de la frontera de Pareto.

1.1.1 Objetivos de la investigación

El objetivo principal de la investigación es desarrollar una metodología para la resolución del problema de distribución en planta de establecimientos industriales atendiendo a múltiples objetivos, siguiendo los principios establecidos por Muther, mediante el empleo de aquellos indicadores que resulten más interesantes. Para alcanzar este objetivo principal se deben satisfacer primero los siguientes objetivos parciales:

- Realizar una recopilación de todos los indicadores que se han empleado como objetivo (ya sea único o en compañía de otros) en la resolución del problema de distribución en planta. Para ello será necesario tener un estado del arte actualizado de las referencias bibliográficas del problema y analizar qué objetivo minimizan o maximizan los diferentes autores.
- Relacionar los objetivos a cubrir por cualquier distribución en planta de procesos industriales establecidos por diferentes autores con los principios básicos establecidos por Muther y con los indicadores propuestos por los distintos autores que se han aproximado al problema.
- Detectar si existe la necesidad de definir algún nuevo indicador para poder optimizar el problema de distribución en planta atendiendo a alguno de los principios de Muther que no tuviera indicador específico.
- Estudiar las diferentes metaheurísticas que se han aplicado en el ámbito de la optimización multiobjetivo, haciendo especial hincapié en las basadas en Simulated Annealing.
- Realizar un estado del arte de las aproximaciones multiobjetivo que se han realizado al problema de distribución en planta en su fase de layout de bloques, analizando tanto técnicas de optimización como formas en las que se considera el carácter multiobjetivo del problema.
- Proponer una metodología basada en frontera de Pareto para la resolución del problema de distribución en planta atendiendo a los indicadores que se consideren de mayor importancia para cubrir los principios básicos de Muther.
- Desarrollar una aplicación informática que permita testear la metodología propuesta sobre un problema de la bibliografía, obteniendo las fronteras de Pareto tanto en 2D (para dos criterios) como 3D (optimizando 3 objetivos).

1.1.2 Estructura de los contenidos

Para alcanzar los objetivos enunciados, se ha estructurado el contenido de la presente tesis doctoral de la siguiente forma:

Capítulo 1. Introducción al problema.

En este capítulo se presenta el problema a resolver, comentando aspectos generales del mismo, las diferentes variantes que se pueden presentar, así como las metodologías que han establecido distintos autores para su resolución. Se establecen los objetivos básicos de la investigación, fijando el camino a seguir para cubrir los mismos.

Capítulo 2. Aspectos geométricos del problema de distribución en planta.

Una vez presentado el problema, en este capítulo se comentarán todos los aspectos geométricos relevantes que se han de tener en cuenta en el planteamiento del problema de distribución en planta. Se estudiarán los modelos geométricos empleados en la bibliografía y se expondrán las ventajas e inconvenientes de cada uno de ellos. Se estudiará también un aspecto ligado con la geometría, como es la métrica de la distancia.

Capítulo 3. Indicadores aplicados al problema de distribución en planta.

Se presentarán los objetivos y principios básicos que debe cumplir cualquier distribución en planta según diferentes autores y se realizará una recopilación de todos los indicadores que han sido empleados por los autores que se han aproximado al problema. Posteriormente se relacionarán los principios básicos con los indicadores propuestos por los diferentes autores y se propondrá un nuevo indicador para cubrir el principio de circulación.

Capítulo 4. Métodos de optimización multiobjetivo.

En este capítulo se realiza una revisión de los aspectos fundamentales relativos a la optimización multiobjetivo. Se resumen algunas nociones básicas de estos tipos de problemas y se realiza un estado del arte de las técnicas metaheurísticas que se han aplicado por los distintos autores a numerosos problemas de optimización.

Capítulo 5. Planteamiento multiobjetivo del problema de distribución en planta.

Con lo visto en apartados anteriores, el problema de distribución en planta es claramente un problema multiobjetivo y en este capítulo se realiza una revisión bibliográfica exhaustiva de todas las aproximaciones al problema desde el punto de vista de la optimización multiobjetivo.

Capítulo 6. Metodología propuesta.

En este capítulo se propondrá una metodología para la resolución del problema multiobjetivo de distribución en planta basada en una variación algoritmo MOSA propuesto por (Gonzalez 2005). Se definirán los mecanismos de construcción y generación de nuevas soluciones, se fijarán los criterios para la generación de la vecindad de una solución en función de las variables que se consideren y se fijarán los criterios generales del algoritmo a emplear.

Capítulo 7. Plan experimental y resultados obtenidos.

Finalmente se aplicará la metodología propuesta sobre un problema de test, en concreto el de 20 actividades propuesto por (Armour y Buffa 1963). Se estudian los valores obtenidos para cada uno de los indicadores, definiendo la frontera de Pareto de los distintos bicriterios para ser comparados con los resultados obtenidos.

Capítulo 8. Conclusiones y trabajos futuros.

Se cierra el trabajo con las conclusiones obtenidas de la investigación, así como la propuesta de trabajos futuros tanto en el campo de la optimización multiobjetivo aplicada al problema de distribución en planta como de los indicadores aplicados al problema.

Bibliografía.

Finalmente se adjuntan todas las referencias bibliográficas empleadas a lo largo de la investigación.

1.2 EL PROBLEMA DE DISTRIBUCIÓN EN PLANTA

1.2.1 Tipos básicos de distribución en planta

La producción es el resultado de la acción combinada y coordinada de un conjunto de operarios que empleando maquinaria actúan sobre las materias primas, dotándolas de un valor añadido bien sea por modificación de su forma o características o combinándolas para convertirlas en un producto.

Por tanto son tres los medios directos de producción que intervienen en el todo proceso: operarios, maquinaria y materiales. Variando la posibilidad de movimiento de cada uno de estos tres medios, se obtienen 7 modos diferentes de producción, tal y como se muestra en la Tabla 1.2.1.

| | Desplazamiento | | | Ejemplos |
|---|----------------|----------|------------|---|
| | Operarios | Material | Maquinaria | |
| 1 | Si | | | Control de calidad y supervisión de procesos. |
| 2 | | Si | | Plantas de envasado, plantas químicas... |
| 3 | | | Si | Talleres mecánicos con maquinaria ligera. |
| 4 | Si | Si | | Fabricación de utillajes en pequeñas cantidades. |
| 5 | Si | | Si | Construcción aeronáutica. |
| 6 | | Si | Si | Talleres mecanizados automatizados. |
| 7 | Si | Si | Si | Montaje de piezas pequeñas con maquinaria ligera. |

Tabla 1.2.1 Modos de producción según el movimiento de los medios y ejemplos.

Si se considera el tipo de movimiento de los medios de producción como el único criterio para establecer las diferentes tipologías de distribución en planta, se obtienen los tipos clásicos de distribución en planta (Francis y White 1974) (Contero Gonzalez 1995), como son:

- Distribución por posición fija.
- Distribución por secciones, por proceso o desplazamiento lento.
- Distribución en cadena, en serie o desplazamiento rápido.
- Distribución por familia de productos o por sistemas de fabricación flexible.

La elección de uno u otro tipo de distribución debe basarse tanto en el movimiento de los medios de producción como la clase de operación de producción que se va a realizar en la industria. Las clases de operaciones de producción más habituales en las industrias de producción son:

1. *Fabricación*. El producto final se obtiene mediante la ejecución de una serie de operaciones encaminadas a cambiar la forma de la materia prima (extrusión de piezas plásticas).
2. *Tratamiento*. El producto final se obtiene mediante la ejecución de una serie de operaciones encaminadas a cambiar las características del material de partida (mecanización de piezas metálicas).
3. *Montaje*. El producto final se obtiene mediante el ensamblaje de diferentes piezas sobre el material de base (montaje de sistemas electrónicos).

A continuación se detallan las características fundamentales de los tres tipos de distribución en planta sobre los que se desarrollan las tres clases de operaciones de producción, cubriendo de esta forma la práctica totalidad de distribuciones en planta de procesos industriales.

1.2.1.1 Posición fija

Este tipo de distribución se caracteriza porque el material o producto que se está elaborando permanece estático durante el proceso de fabricación. Se emplea esta distribución en la construcción de productos muy voluminosos y pesados, cuyo movimiento es prácticamente inviable.

Se pueden producir partes del producto final en otras secciones y finalmente ser ensambladas en posición fija. Ejemplos de este tipo de distribución pueden ser la fabricación de aviones y barcos (ver Figura 1.2.1) o en edificación u obra pública.



Figura 1.2.1 Distribución por posición fija (tomada de www.navalgijon.es).

1.2.1.2 Por secciones, por proceso o desplazamiento lento.

Se adopta una distribución por secciones (también denominada por proceso o de desplazamiento lento) cuando se agrupan las operaciones de una misma naturaleza en una misma zona de la planta, como ocurre cuando se produce una amplia gama de productos que requieren la misma maquinaria, aunque con volúmenes de producción reducidos.

La agrupación de la maquinaria da lugar a *talleres de operación*, donde se ejecutan tareas específicas a los que los materiales son sometidos en función de tipo de producto a elaborar. Este tipo de distribución dota a la industria de una gran flexibilidad, aunque requiere sistemas de mantenimiento efectivos y funciona de manera aceptable con bajos volúmenes de producción.

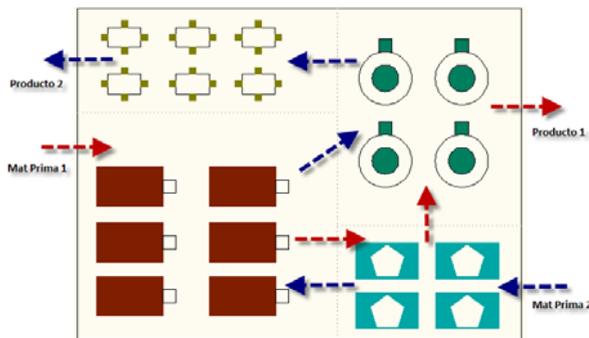


Figura 1.2.2 Distribución por secciones.

Se emplea una distribución por secciones en plantas textiles, en talleres de mecanizado de piezas, o en talleres mecánicos, que se estructuran siempre por operaciones.

1.2.1.3 En cadena, en serie o desplazamiento rápido.

Si la maquinaria y los equipamientos, así como los operarios se mantienen siempre en la misma posición y lo único que se desplaza son los materiales se empleará una distribución en planta en cadena (también denominada en serie, de desplazamiento rápido o por producto). La maquinaria se sitúa de forma que la distancia y los tiempos de desplazamiento de los materiales entre operaciones sean mínimos.

Este tipo de distribución se emplea cuando hay que producir mucha cantidad de pocos productos diferentes, por ejemplo: en plantas embotelladoras, en industrias químicas, en fábricas de automóviles...Su principal problema es la falta de flexibilidad y capacidad de adaptación a cambios.

Figura 1.2.3 Distribución en planta en cadena.

1.2.1.4 En sistemas de fabricación flexibles, por grupos homogéneos o por familia de productos.

La distribución en planta por familia de productos (por sistemas de fabricación flexibles o por grupos homogéneos) se basa en la constitución de grupos de máquinas que son capaces de producir una serie de piezas y que son agrupadas en una zona de la planta para facilitar el desplazamiento del material y reducir los costes de manutención y los almacenajes intermedios de productos. La agrupación se puede realizar mediante técnicas de *clustering* que permiten, a partir de una serie de características comunes a los productos a fabricar, agruparlos por familias. Esta agrupación se puede realizar fundamentalmente en dos tipos de elementos:

- Una *célula de fabricación flexible*, que puede definirse como el conjunto maquinas diferentes ordenadas de acuerdo con una secuencia de operaciones que permite procesar un conjunto de piezas que requieren las mismas operaciones, en la misma secuencia y con ciclo de máquina similares.
- Una *semi-célula de fabricación*, que es un conjunto de máquinas que ejecutan todas las operaciones requeridas para producir un conjunto de piezas que tienen las mismas operaciones pero no la misma secuencia o cuando teniendo la misma secuencia los ciclos de máquina para cada pieza varían considerablemente. Requieren mayor espacio de almacenamiento e implican mayor trabajo en curso (WIP).

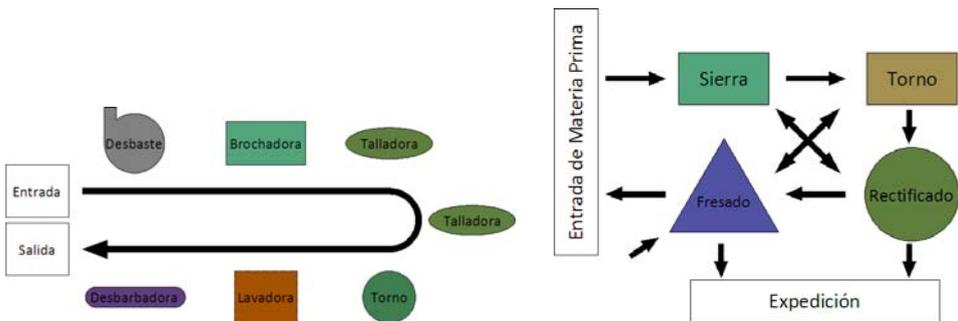


Figura 1.2.4 Célula de fabricación flexible (izda.) y semicélula de fabricación (der).

Este sistema productivo reduce los inventarios de materias primas y productos intermedios, y todo ello redunda en unas menores necesidades espaciales de la planta, dotando a la industria a su vez de una mayor flexibilidad de producción. No obstante, no todos las industrias pueden adoptar este modo de distribución en planta.

En la Tabla 1.2.2 se muestran las características más importantes de los tipos básicos de distribución en planta, tomado de (Adam y Ebert 1991) y (Santamarina 1995).

| Atendiendo a | Posición Fija | Por proceso | En Cadena | Sistemas de Fabricación Flexibles |
|---|--|--|---|--|
| Producto | -Bajo pedido. -Bajo volumen producción. | -Varios productos con operaciones comunes. -Volumen de producción variable. -Demanda variable. | -Productos estándar. -Alto volumen de producción. -Demanda estable. | -Series pequeñas y medianas (lotes). -Flexibilidad. Gama de productos amplia. |
| Líneas flujo material | -No existen. -Material con posición fija. | -Líneas entremezcladas. | -Procesos lineales. -Secuencias iguales para todos los productos | -Cortas y sencillas. |
| Cualificación del trabajador | -Alta flexibilidad de operaciones. -Alta cualificación | -Intermedia. | -Rutinario y repetitivo -Especializado | -Solo supervisión. |
| Necesidad de personal | -Programación y coordinación. | -Personal de planificación, manejo de materiales, producción y control de inventarios. | -Gran cantidad -Planificación de material-operarios -Trabajo de control y mantenimiento | -Prácticamente nula, sólo para supervisión general |
| Manejo de materiales | -Flujo variable. -Equipos de manejo generales. | -Flujo variable. -Equipos de manejo a menudo duplicados. | -Predecible -Flujo sistemático y automatizable | -Síncrono, totalmente automático. |
| Inventarios | -Variables, con continuas modificaciones. | -Largos. -Mucho trabajo en curso. | -Mucha rotación de materiales, inventarios reducidos | -Mucha rotación de materiales, inventarios reducidos. |
| Uso del espacio (Uds./m²) | -Bajo. | -Bajo. -Alto requerimiento por trabajo en curso. | -Alta. | -Muy alta. |
| Inversión | -Equipos y procesos móviles de propósito general. | -Equipos y procesos flexibles. | -Elevada con equipos especializados. | -Elevada con equipos especializados. |
| Coste del producto | -Costes fijos bajos. -Costes variables elevados (mano de obra y materiales) | -Costes fijos bajos. -Costes variables elevados (en material y transporte) | -Costes fijos elevados -Costes variables bajos (en mano obra y materiales) | -Costes fijos elevados. -Costes variables bajos. |

Tabla 1.2.2 Características de los tipos básicos de distribución en planta.

1.2.2 Metodologías clásicas para la resolución del problema de distribución en planta

A lo largo de los años 50-70 aparecieron diferentes metodologías para la resolución, de manera sistemática, del problema de distribución en planta de procesos industriales. La que tiene un mayor prestigio y que ha sido catalogada como la más completa, es el SLP propuesto por (Muther 1968), sin embargo hasta llegar a ella, otros autores realizaron aproximaciones empleadas posteriormente en el SLP.

1.2.2.1 Primeras aproximaciones

1.2.2.1.1 *Immer*

El primer intento por establecer una metodología estructurada para la resolución del problema de distribución en planta la realizó (Immer 1950). Pese a ser una metodología extremadamente sencilla, se destaca precisamente por ser la primera. Es un método de mejora de una distribución existente, bien sea mediante la reordenación de la misma o realizando ajustes menores.

La metodología se centra en un único objetivo, el coste de mantenimiento (MHC, o flujo entre actividades) y consta de tres puntos:

1. Plantear correctamente el problema a resolver.
2. Detallar las líneas de flujo.
3. Convertir las líneas de flujo en líneas de maquinaria.

1.2.2.1.2 "*Sequence analysis*" de Buffa

La propuesta realizada en (Buffa 1955) es una metodología mucho más desarrollada que la anterior y que guarda alguna similitud con el SLP que se comentará más adelante. El autor la denomina *Sequence analysis* y consta de las siguientes etapas:

Etapas 1: Estudio del proceso

Recopilar los datos referentes al recorrido de las piezas y organización de los mismos en forma de hojas de ruta. Realizar el análisis de los requerimientos del sistema productivo

Etapas 2: Establecer la secuencia de las operaciones

Elaborar una tabla resumen (*Sequence summary*), estableciendo la secuencia de operaciones a realizar sobre cada una de las piezas.

Etapas 3: Generar la tabla de cargas

Desarrollar una tabla de cargas de transporte (*Load summary*), expresando las cargas de transporte mensuales entre las diferentes actividades de la planta.

Etapa 4: Obtención del diagrama esquemático ideal

El autor propone el empleo del diagrama esquemático ideal, un grafo en el que las diferentes actividades se representan mediante círculos. Cada actividad se une, mediante una línea, a todas aquellas con las que tiene una relación de flujo de materiales colocando sobre ella el volumen de unidades transportadas al mes. Se debe intentar que el numero de cruzamientos entre líneas sea mínimo y que las actividades con mayor intensidad de tráfico de material estén situadas lo más cerca posible.

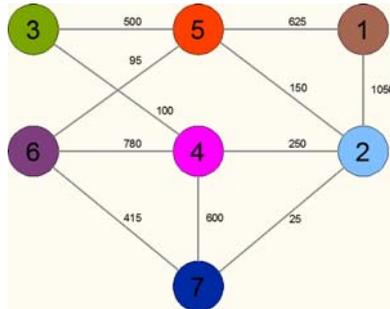


Figura 1.2.5 Ejemplo de diagrama esquemático ideal de Buffa.

Etapa 5: Desarrollo del diagrama de bloques

A partir del diagrama esquemático ideal se obtiene el diagrama de bloques (*block layout*), en el que se dota a cada una de las actividades (hasta ahora sin área) de sus dimensiones reales, respetando la posición relativa obtenida en la etapa anterior.

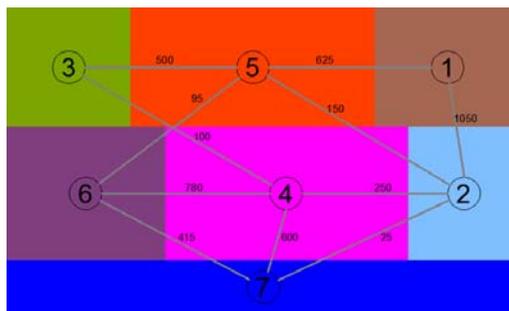


Figura 1.2.6 Diagrama de bloques (*block layout*) de Buffa.

Etapa 6: Desarrollo de la distribución de detalle

En esta etapa se concluye el diseño mediante el desarrollo de la distribución de detalle (*detail layout*) en la que se dota a cada actividad de la posición final de las maquinas, con los puntos de entrada y salida de materiales, sistemas de mantenimiento...

1.2.2.1.3 "Systematic plan of attack" de Reed

Otra de las aproximaciones metodológicas para la resolución del problema de distribución en planta de establecimientos industriales, es la de (Reed 1961) que viene recogida en (Tompkins y White 1984) y que define como "plan sistemático de ataque", con los siguientes pasos:

1. Analizar el producto a fabricar.
2. Determinar el proceso necesario para fabricarlo.
3. Preparar las tablas de planificación de la configuración.
4. Determinar las actividades.
5. Analizar los requerimientos de almacenamiento.
6. Fijar las dimensiones y posiciones de los pasillos.
7. Establecer las necesidades de espacio para los trabajos administrativos.
8. Considerar los servicios auxiliares de la planta.
9. Planificar los servicios de la planta.
10. Prever futuras expansiones de la planta.

El autor le da una importancia vital a las tablas de planificación, y la califica como "la fase más importante de toda la metodología", debiéndose incorporar:

- Estudio del flujo de materiales, operaciones, transporte, almacenamiento e inspecciones.
- Tiempos requeridos en cada punto.
- Selección de maquinaria requerida.
- Mano de obra requerida.
- Requerimientos de manutención.

1.2.2.1.4 "Ideal systems approach" de Nadler

En (Tompkins y White 1984) también se expone la metodología propuesta por (Nadler 1965), denominada "*ideal systems approach*", y que pese a estar pensada para el diseño de sistemas de manutención es extensible a la resolución del problema de distribución en planta.

Tal y como se destaca en (Diego-Más 2006), es más una filosofía de trabajo que una metodología en sí. Esta aproximación se realiza partiendo del sistema ideal teórico que resuelve el problema para ir descendiendo hasta alcanzar una solución factible al problema (sistema real). A continuación se comentan los distintos tipos de sistemas que se describen en la propuesta, desde los más abstractos a los más reales.

El *sistema teórico ideal* es un sistema perfecto, de coste cero, calidad absoluta, sin riesgos y absolutamente eficiente. El *sistema ideal último* representa la solución que con la tecnología actual no es implementable, pero que presumiblemente a corto plazo si que lo sea. El *sistema ideal tecnológicamente viable* representa la mejor solución que se puede alcanzar con la tecnología actual, pero que no se materializa debido a su elevado coste. El *sistema recomendado* es una solución válida al problema, materializable con la tecnología disponible y con una aceptable eficiencia. El *sistema real* es la implementación efectiva de la solución.

1.2.2.1.5 Metodología de Apple

En (Apple 1968) se establece una secuencia de pasos a realizar (no necesariamente en orden), para considerar todos los aspectos relevantes durante la generación de una distribución en planta de una nueva industria. Los diferentes pasos son:

1. Obtener los datos básicos del problema.
2. Analizar los datos.
3. Diseñar el proceso productivo.
4. Proyectar los patrones de flujo de los materiales.
5. Planificar los sistemas de mantenimiento generales.
6. Calcular los requerimientos de equipamiento.
7. Planificar cada sección de trabajo (actividad).
8. Seleccionar los sistemas de mantenimiento específicos.
9. Coordinar los conjuntos de operaciones relacionadas.
10. Diseñar las relaciones entre actividades.
11. Determinar las necesidades de almacenamiento.
12. Planificar los sistemas auxiliares de la planta.
13. Calcular los requerimientos espaciales.
14. Ajustar las actividades al espacio disponible.
15. Considerar diferentes sistemas estructurales para el edificio.
16. Construir la distribución en planta maestra.
17. Evaluar, ajustar y revisar la distribución.
18. Obtener las correspondientes aprobaciones.
19. Instalar la distribución obtenida.
20. Hacer un seguimiento del funcionamiento de la planta.

1.2.2.2 *Systematic Layout Planning (SLP)*

La metodología más detallada y aceptada para la resolución del problema de distribución en planta es el *Systematic Layout Planning* (en adelante SLP) propuesta por (Muther 1968). Es una forma organizada de realizar la planificación de una distribución en planta y está constituida por cuatro fases, estructuradas en una serie de procedimientos que permiten identificar, evaluar y visualizar los elementos y las áreas involucradas en la planificación.

Es un procedimiento de trabajo eficiente y que puede ser aplicado a numerosos problemas de distribución, ya sea de industrias, hospitales, laboratorios... La metodología se asienta sobre el conocimiento profundo de todos los aspectos que son relevantes en el correcto funcionamiento del sistema a resolver. Por ello es de vital importancia que antes de comenzar a realizar la planificación se disponga de toda la información necesaria para completar las diferentes etapas en lo relativo a:

1. Producto (P): Se deben conocer todos los datos relativos a los productos que se van a mover en la planta tanto las materias primas, productos semielaborados y los acabados.
2. Cantidad (Q): También es necesario tener cuantificadas las cantidades de todos los productos enunciados anteriormente que se mueven por la planta.
3. Recorrido (R): Entendiéndose como recorrido la secuencia y el orden de las operaciones a la que deben someterse los diferentes productos.
4. Servicios (S): En cualquier sistema de producción los servicios auxiliares de producción tienen una gran importancia, deben preverse todas las interacciones entre operarios, actividades, tareas de supervisión...
5. Tiempo (T): Puede considerarse también mediante las cantidades de productos, puesto que éstas se refieren siempre a un periodo de tiempo determinado.

Con la recopilación de toda la información comprendida en los cinco puntos anteriores se puede comenzar la etapa de desarrollo del SLP, debiéndose cubrir cinco fases:

- Análisis P-Q
- Análisis de recorrido de productos
- Análisis de relación entre actividades
- Diagrama relacional de recorridos
- Diagrama relacional de espacios

A continuación se comentan los aspectos más relevantes de cada una de las cinco fases de la metodología.

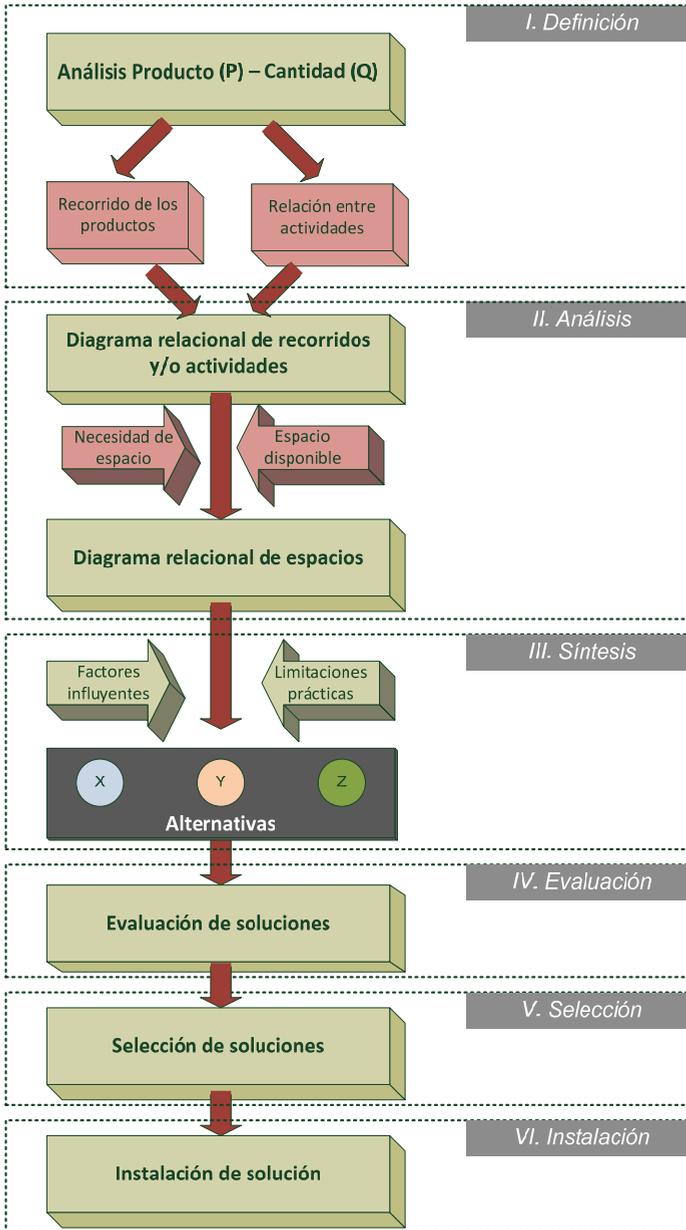


Figura 1.2.7 Esquema de etapas de la metodología SLP (Muther 1968).

1.2.2.2.1 Fase de definición

Análisis P-Q

Tal y como se puede observar en el esquema de etapas del SLP, mostrado en la Figura 1.2.7, toda la metodología comienza con un análisis detallado de la cantidad de productos producidos en la planta en proyecto (P), y las cantidades de cada uno de ellos (Q). Toda esta información, tanto la de P como la de Q, debe servir al proyectista para decidir el tipo de distribución básica de entre los comentados en puntos anteriores del presente trabajo (posición fija, producto, proceso...) se debe emplear. El propio Muther recomienda utilizar una gráfica (en forma de histograma de frecuencias) para representar la relación P-Q y poder determinar así el tipo de distribución básica. Los productos se colocan (ordenados por número de unidades producidas) en las abscisas y la cantidad de unidades producidas en las ordenadas.

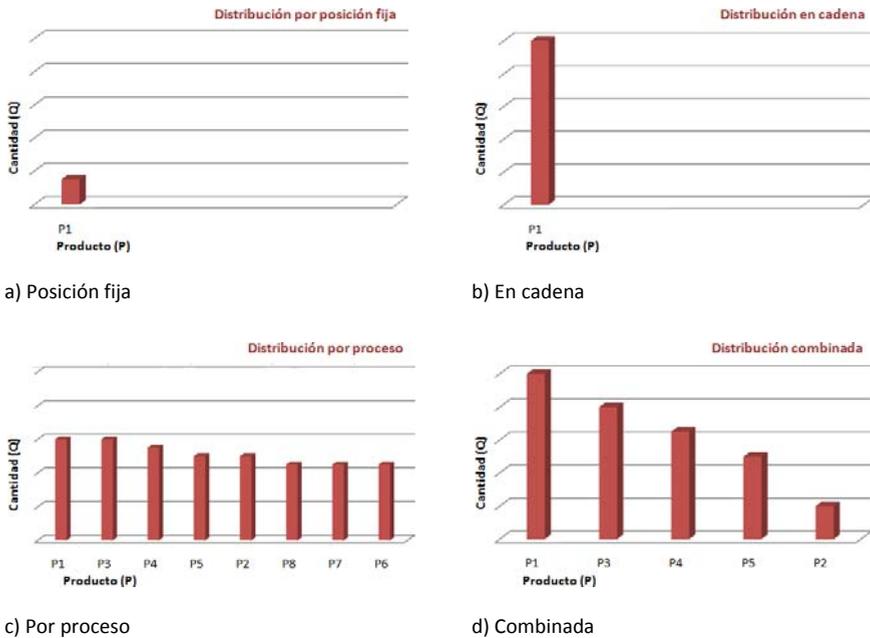


Figura 1.2.8 Análisis de gráficos P-Q y distribuciones básicas asociadas.

En la Figura 1.2.8 se muestran las cuatro posibles situaciones que conduzcan a los tipos básicos de distribución en planta. Si se producen pocos productos y en pequeñas cantidades (a), se puede relacionar con una distribución en planta por *posición fija*. Si se producen cantidades elevadas de pocos productos (b), se debe adoptar una *distribución en cadena*. Cuando se producen cantidades similares de muchos productos (c) se debe optar por una distribución *por proceso*. Si el gráfico P-Q es del tipo (d), se puede optar por una *distribución mixta*, combinando todas las anteriores, para conseguir una mejor adaptación a la producción demandada.

Análisis de recorrido de productos

Una vez conocido el tipo de distribución básica a emplear y el gráfico P-Q correspondiente, se debe determinar la secuencia, cantidad y el coste de manutención de los productos que se vayan a mover en toda la planta. A partir del proceso productivo de los diferentes productos y de los volúmenes de producción asociados a cada uno de ellos. Tal y como se profundizará en apartados posteriores de este trabajo, este punto es de gran importancia, pues el movimiento de materias primas a través de la planta es uno de los objetivos de mayor importancia a considerar a la hora de optimizar la distribución en planta de procesos industriales, siempre y cuando:

- Los volúmenes y materiales movidos sean considerables.
- El coste de manutención sea elevado con los costes de operaciones.

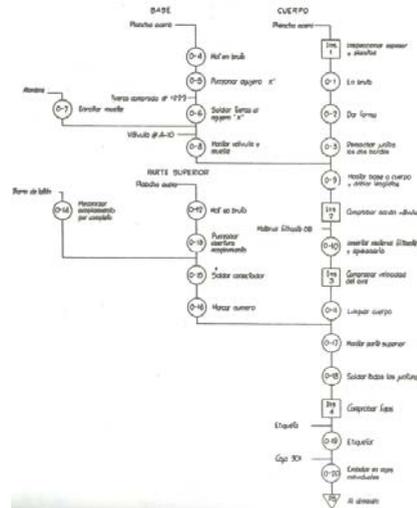
Para realizar el análisis de recorrido de los productos en la planta, se pueden utilizar diferentes herramientas como tablas y diagramas, que facilitan y estructuran la tarea en función del número de productos y del volumen de producción, tal y como destaca (Santamarina 1995) son:

| Operación | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 |
|--------------------|---|---|---|---|---|---|---|---|---|
| 1. Colar Sólido | | | | | | | | | |
| 2. Riqueto Marfile | | | | | | | | | |
| 3. Colar Demuecho | | | | | | | | | |
| 4. Seta Plastico | | | | | | | | | |
| 5. Desc. Tubos | | | | | | | | | |
| 6. Limpado | | | | | | | | | |
| 7. Inspección | | | | | | | | | |
| 8. Embalaje | | | | | | | | | |
| 9. Emboraje | | | | | | | | | |

a) Tabla Matricial

| Area fab. | 1774 | 1775 | 1776 | 1777 | 1778 | 1779 | 1780 | 1781 | 1782 | 1783 | 1784 |
|-------------------|------|------|------|------|------|------|------|------|------|------|------|
| 1 Colar sólido | 1 | | | | | | | | | | |
| 2 Riqueto marfile | | 1 | | | | | | | | | |
| 3 Colar demuecho | | | 1 | | | | | | | | |
| 4 Seta plastica | | | | 1 | | | | | | | |
| 5 Desc. Tubos | | | | | 1 | | | | | | |
| 6 Limpado | | | | | | 1 | | | | | |
| 7 Inspección | | | | | | | 1 | | | | |
| 8 Embalaje | | | | | | | | 1 | | | |
| 9 Emboraje | | | | | | | | | 1 | | |

b) Diagrama Multiproducto



c) Diagrama de recorrido sencillo

Figura 1.2.9 Herramientas para el análisis del recorrido (Muther 1981).

- *Diagramas de recorrido sencillo.* Si se producen muy pocos productos independientemente del volumen de producción.
- *Diagramas de recorrido multiproducto.* Si se producen pocos productos.
- *Tabla Matricial.* Si se producen muchos productos diferentes en pequeñas cantidades.

Análisis de relación entre actividades

Sin embargo el flujo de materiales en la planta no es el único factor que se debe tener en cuenta a la hora de planificar la distribución del proceso, sino que también hay que considerar otros aspectos que son de gran importancia en la misma, como son los relativos a la integración de los medios auxiliares de producción. En esta fase, el proyectista debe considerar en esta etapa las exigencias constructivas, los aspectos de seguridad e higiene en el trabajo, los sistemas de mantenimiento, los consumos energéticos, los sistemas de información...

Para poder representar las relaciones encontradas de una manera lógica y que permita clasificar la intensidad de las mismas, (Muther 1968) propone emplear la tabla relacional de actividades (Figura 1.2.10). En la misma se expresa de forma gráfica la relación (cualitativa) entre cada par de actividades de la planta. Se emplea un código de letras que van desde la necesidad de proximidad de dos actividades (A) hasta la incompatibilidad de dos actividades (X).

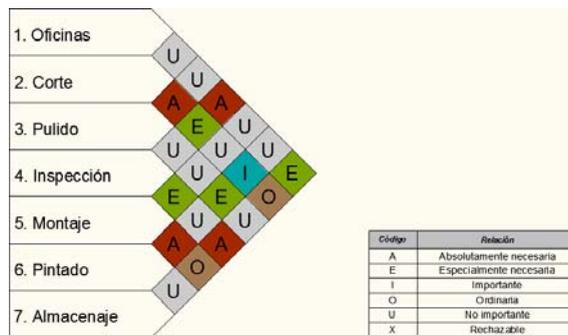


Figura 1.2.10 Ejemplo de tabla relacional de actividades.

El análisis de recorridos comentado anteriormente cubre las relaciones entre las actividades de producción y la tabla relacional considera todos los aspectos relativos a la integración de los medios auxiliares de producción.

En la propia confección de la tabla relacional de actividades, se hace patente el carácter multiobjetivo del problema de distribución en planta, ya que es una práctica habitual asociar a cada valor de relación entre actividades un código numérico que muestre el motivo que ha motivado la asignación de la relación A, E, I, O, U ó X.

1.2.2.2.2 Fase de Análisis

Una vez recopilada toda la información relativa a los flujos entre actividades y a las necesidades de proximidad de las mismas, comienza la fase de análisis de la metodología, para ello se emplean dos diagramas propuestos por el autor para determinar la posición relativa de las actividades en la planta, y que se describen brevemente a continuación.

Diagrama relacional de recorridos y/o actividades

Con los datos obtenidos en la tabla relacional de actividades, se realiza una representación en forma de grafo, que muestre las relaciones existentes entre las actividades ya sean a nivel de flujo entre las mismas o a nivel de proximidad. El diagrama resultante sobre el que se muestran todas las relaciones (Muther 1968) lo denomina "*Diagrama relacional de recorridos y/o actividades*", que guarda ciertas similitudes con el diagrama esquemático ideal de (Buffa 1955). Ambos autores buscan una ordenación topológica de las actividades.

En el diagrama, las actividades se representan mediante nodos, que son unidos entre sí en función de la relación existente entre las mismas. La intensidad de la relación entre actividades se refleja mediante la inclusión de un número (en el caso de flujo) o letras (en el caso de relaciones cualitativas) junto a las líneas. La ordenación de los nudos del grafo debe realizarse de tal manera que las actividades más afines (o aquellas con mayor volumen de flujo) queden próximas, intentando que no se produzcan cruzamientos entre líneas, o que si se producen no sea en aquellas que tienen una mayor afinidad, ya sea de flujo o de relación

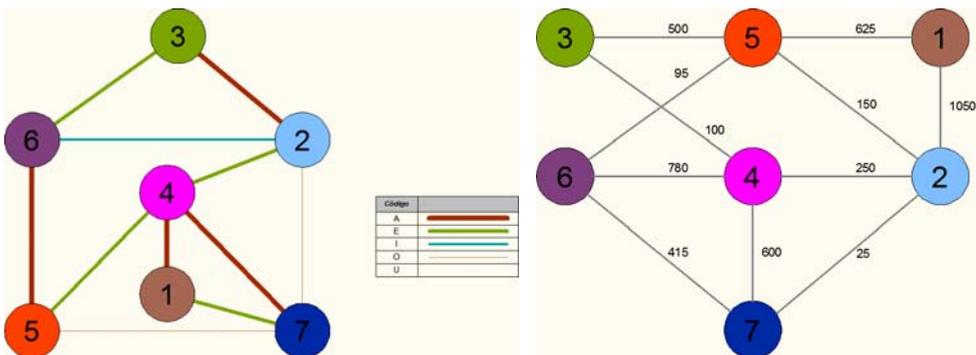


Figura 1.2.11 Ejemplo de diagrama relacional de actividades (izda.) y diagrama relacional de recorridos (der.).

Tal y como se comentará en capítulos posteriores de esta tesis, en teoría de grafos, obtener un diagrama con estas características se denomina localizar un *grafo planar ponderado maximal*, y existe toda una línea de trabajo de generación de layouts atendiendo a esta técnica.

Diagrama relacional de espacios

Una vez obtenidos los diagramas relacionales de actividades y recorridos, con el menor número de cruces posibles en los recorridos entre departamentos, se debe pasar a dar forma a las actividades, determinando primero el área necesaria para cada una de ellas.

El proyectista debe hacer uso de herramientas de cálculo de los espacios requeridos por cada una de las actividades, ver (Santamarina 1995), y verificar que el espacio disponible para implantar cada una de ellas es suficiente. Si las necesidades no casan con las disponibilidades, deberá realizarse un reajuste entre ambas, reformando o ampliando las edificaciones o espacios previstos para la implantación del proceso o bien disminuyendo (en la medida de lo posible) el espacio asignado a cada una de las actividades. Este suele ser un proceso iterativo que desemboca en el Diagrama relacional de espacios, que utiliza la base de los diagramas anteriormente obtenidos, convirtiendo los nodos, con los que se representaban las actividades, por rectángulos de un área determinada.

En la Figura 1.2.12 se muestra un diagrama relacional de espacios asociado al diagrama relacional de actividades que se planteó en la Figura 1.2.11.

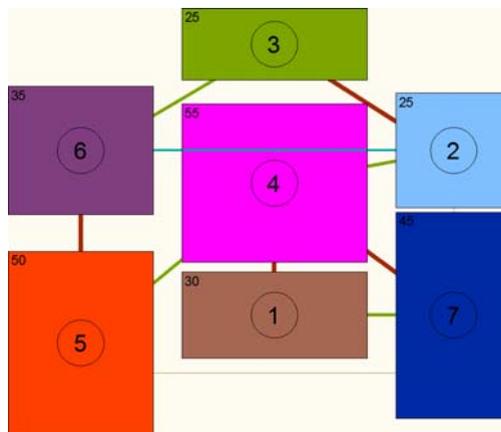


Figura 1.2.12 Ejemplo de diagrama relacional de espacios.

En el presente trabajo, las áreas de las actividades son conocidas, así como el recinto sobre el que se va a implantar el proceso, tal y como se comentará en apartados posteriores.

1.2.2.2.3 Fase de Síntesis

Una vez finalizada la fase de análisis, habiendo obtenido los diagramas que resumen toda la información necesaria para generar diferentes configuraciones que resuelvan efectivamente el problema estudiado, se pasa a la fase de síntesis, que tiene por objetivo fundamental la obtención de un conjunto de soluciones válidas para el problema de distribución en planta.

En este punto es importante remarcar que el problema no tiene una solución única, pues si bien es posible encontrar óptimos locales atendiendo a un indicador u objetivo, es muy complicado poder asegurar de forma categórica que ese mínimo local pueda serlo también global. Aun pudiendo probar que el mínimo sea global, lo es únicamente atendiendo a ése indicador, y si atendemos a otros objetivos, es muy probable que ya no sea un mínimo.

Muther emplea varias técnicas para la generación de alternativas, pero la gran mayoría están basadas en el empleo de maquetas o en mera intuición del proyectista. Con los años, han ido apareciendo (a medida que las herramientas informáticas se han desarrollado), distintos métodos de generación de alternativas, fase en la que se centra la presente tesis. Todas estas técnicas se comentan con mayor detalle en el punto 1.2.2.3.

1.2.2.2.4 Fase de Evaluación

En la siguiente fase de proceso, la fase de evaluación, se debe valorar la solución propuesta es la más apropiada para la planta en estudio. Para ello habrá que desarrollar un layout de detalle (*detail layout*) en el que se especifiquen los puntos de entrada y salida de los materiales en cada una de las actividades, la posición de la maquinaria, espacios de seguridad, anchura de los pasillos...

Una vez definido el layout de detalle, se debe valorar la solución obtenida desde otros objetivos que se consideren importantes en la industria, pues con toda seguridad, si la optimización que se ha realizado en la fase de síntesis se ha abordado sobre un único objetivo, se habrán desatendido otros criterios que pueden resultar muy importantes en la planta. En el caso de abordar el problema atendiendo a múltiples objetivos, se obtienen un conjunto de soluciones que son las óptimas atendiendo a los diferentes criterios.

1.2.2.2.5 Fase de Selección

Si se acomete el problema de distribución en planta tal y como lo enuncia Muther en su metodología, se deben tener en cuenta múltiples criterios, y bien sea mediante una formulación multicriterio (como se ha optado en este trabajo) o con una sucesión de optimizaciones monobjetivo, en este punto de la metodología se deben disponer de una serie de soluciones óptimas en unos objetivos, aunque no tan óptimas en el resto.

El enfoque multicriterio permite obtener un conjunto de soluciones eficientes atendiendo a los diferentes criterios que entren en juego en la implantación, obteniendo soluciones intermedias que sin ser óptimas atendiendo a un único criterio, sí que son lo suficientemente buenas en el conjunto y, por tanto, puedan ser seleccionadas como apropiadas. Por tanto, se culmina la fase de síntesis con un conjunto de soluciones que ya son eficientes, quedando para esta última un trabajo más simple.

Si se aborda el problema desde un único criterio (o mediante varias optimizaciones atendiendo a diferentes criterios), se parte para esta fase de un conjunto de soluciones buenas atendiendo a un único criterio, pero que pueden resultar pésimas en otros.

Por tanto se disponen de una serie de soluciones, de entre las cuales se debe seleccionar la más apropiada para la implantación, pudiéndose emplear técnicas de selección y evaluación e alternativas, de entre las que se pueden destacar:

- ELECTRE (*ELimination Et Choix Traduisant la REalité*).
- AHP (*Analytic Hierarchy Process*).
- DEA (*Data Envelopment Analysis*).

que serán referenciadas en el punto **5.1** del presente trabajo.

1.2.2.2.6 Fase de Instalación

En esta fase se desarrollan los proyectos específicos para una correcta implantación de la industria que se ha optimizado, comprobando la efectividad de la solución propuesta.

1.2.2.3 Métodos de generación de layouts.

La presente investigación se enmarca en la fase de síntesis del SLP de Muther, en la que se deben obtener soluciones viables para la industria en proyecto. En esta obtención de soluciones, y con los medios disponibles en la actualidad se emplean los denominados MGL o *métodos de generación de layouts*, constituidos por algoritmos diseñados para la resolución del problema, mediante los datos obtenidos en fases anteriores.

"...se entiende por Métodos de Generación de Layouts al conjunto de técnicas que ayudan al proyectista en la búsqueda de una solución para la implantación de la planta industrial."

(Santamarina 1995)

Los métodos consiguen una ordenación topológica de las actividades que intervienen en el problema y se centran en la fase de la distribución de bloques (*block layout*), dejando para pasos posteriores el desarrollo de la distribución de detalle (*detail layout*). Surgen a raíz de la formulación matemática del problema de distribución en planta como un problema cuadrático de asignación, QAP (Koopmans y Beckman 1957).

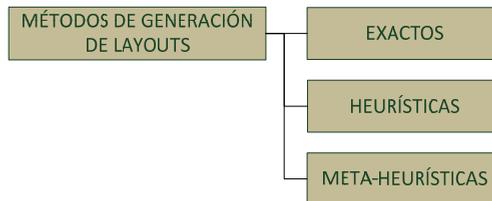


Figura 1.2.13 Clasificación de los Métodos de Generación de Layouts.

A continuación se realiza una breve descripción de cada una de las técnicas de generación de layouts que se han empleado en los últimos años. La práctica totalidad de ellas se han aplicado al problema de distribución en planta monobjetivo, por tanto simplemente se introducirán las técnicas y se darán referencias que podrán ser consultadas para más información. En el capítulo 4 se profundizarán en aquellas técnicas que se han empleado en la aproximación multiobjetivo al problema.

1.2.2.3.1 Métodos exactos (óptimos)

En los primeros tiempos se emplearon **métodos exactos** para la generación de layouts (enumerativos, basados en técnicas *branch and bound* y los algoritmos de planos de corte), que persiguen encontrar una solución óptima del problema. No obstante, pronto se descartó esta vía por ser extremadamente lenta y difícil de abordar cuando el tamaño del problema comenzó a ser grande. A raíz de la aparición de estos problemas, aparecieron una serie de métodos alternativos que se han desarrollado con éxito durante las últimas décadas.

- *Enumerativos*. Este tipo de métodos se busca la generación de todas las posibles soluciones al problema. Para ello es necesario realizar un gran número de simplificaciones (adoptar una formulación tipo QAP con actividades de área igual y sin forma), y aun así es imposible adoptarlo para problemas de tamaño medio, pues se disparan la cantidad de soluciones a evaluar (para 15 actividades son $15!$, es decir 1.3 billones de alternativas).
- *Branch and Bound*. Las primeras referencias a este tipo de algoritmos de resolución, aplicados a problemas cuadráticos de asignación (QAP), se pueden encontrar tanto en (Gilmore 1962) como en (Lawler 1963). Para emplear esta técnica, primero se debe conseguir una solución inicial, que puede ser generada por cualquiera de los algoritmos de construcción que se comentan en puntos posteriores. Esta solución inicial se toma como una cota superior del problema, para subdividir posteriormente el problema en una serie de subproblemas (fase de ramificación), estableciéndose una cota inferior para cada uno de estos y comparando la solución de los éstos con la inicial. Si una de las soluciones de los subproblemas es menor que la solución inicial (y es factible), el nodo queda sondeado (no es posible encontrar una mejor por esa rama). Si no es factible se ramifica y se continúa el proceso de búsqueda. El proceso finaliza tras inspeccionar todas las ramificaciones.
- *Planos de corte*. Esta metodología se emplea en la resolución de problemas MILP (programación lineal entera mixta), y fue introducida por (Aiello, Enea y Galante 2006), aunque no sería empleado en el ámbito de la distribución en planta hasta algo después. En un problema de optimización lineal con un conjunto elevado de restricciones, el procedimiento consiste en calcular la solución óptima con un conjunto reducido de restricciones. Una vez encontrado este “óptimo relajado” se intentan localizar las restricciones que son cumplidas por el problema original, pero incumplidas por aquel. Estas restricciones serán los *planos de corte* del campo de soluciones. Estos planos de corte se añaden al problema relajado, de forma que se recorta el campo de soluciones, aproximándolo al del problema original. El procedimiento se repite hasta que el óptimo del problema relajado cumple con las restricciones del problema original.

1.2.2.3.2 Heurísticas específicas del problema

Dada la extrema dificultad de resolver el problema de distribución en planta (FLP) de manera óptima o exacta, los investigadores buscan vías alternativas para resolver el problema de una forma aproximada.

Los **métodos heurísticos** (o técnicas heurísticas) tienen por objetivo encontrar una solución que sin ser un óptimo global del problema, se aproximen (en algunos casos lo consiguen) a él. Se pueden definir como:

“... 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.”

(Adenso-Díaz et al. 1996)

Los mismos autores destacan que el empleo de los métodos heurísticos es especialmente importante cuando se dan alguna de las siguientes circunstancias:

- No existe un método exacto de resolución.
- No se necesita una solución óptima.
- Los datos son poco fiables.
- Existen limitaciones de tiempo o espacio de almacenamiento a la hora de resolver el problema.
- Como paso intermedio en la aplicación de otro algoritmo.

En los años posteriores a la aparición del SLP, y con los medios disponibles en aquel entonces, los investigadores dejaron de lado los métodos exactos y desarrollaron una serie de heurísticas propias para la generación de layouts. El número de heurísticas es elevado (alrededor de 50) y cada una de ellas era aplicable para casos particulares, pudiéndose realizar diferentes clasificaciones según distintos criterios. De entre estas clasificaciones se puede destacar la descrita en (Hospitaler y Grau 1988).

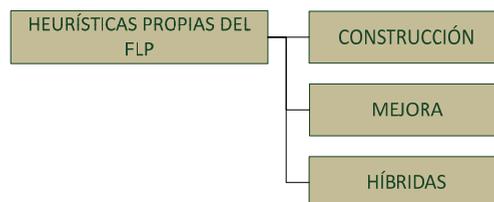


Figura 1.2.14 Heurísticas propias del problema de distribución en planta.

En el punto 2.1.2 del presente trabajo se describen con mayor detalle las heurísticas comentadas en la Figura 1.2.14, que en general fueron concebidas para una aproximación monobjetivo al problema, y que después, parcialmente se amplían al caso de más objetivos. A continuación se describen a grandes rasgos los tres grupos y las técnicas más importantes de cada uno de estos grupos, se pueden encontrar revisiones más profundas en (Santamarina 1995), (Gonzalez 2005) o (Diego-Más 2006).

- *Construcción.* Estos métodos generan diferentes layouts variando la secuencia de colocación de las actividades en la fase de construcción del algoritmo. Todas las heurísticas de este tipo evalúan el incremento (o decremento) de coste surgido al cambiar la posición en la secuencia de colocación de las actividades sobre el dominio, y por lo general, solo cambian a nuevas configuraciones en el caso que se produzca un decremento del coste. Las heurísticas de construcción más conocidas son ALDEP (Seehof y Evans 1967), CORELAP (Lee y Moore 1967), y PLANET (Apple y Deisenroth 1972).
- *Mejora.* Las heurísticas de mejora parten de una solución generada mediante un constructor, a partir de la cual se van obteniendo soluciones alternativas mediante la aplicación de cambios sistemáticos. La solución inicial en las primeras técnicas era siempre aleatoria, aunque posteriormente se obtiene siempre de una heurística previa, dando lugar los métodos híbridos. Las heurísticas de mejora más conocidas son: CRAFT (Armour y Buffa 1963), COFAD (Tompkins y Reed 1976) y MULTIPLE (Bozer, Meller y Erlebacher 1994).
- *Híbridos.* Estas heurísticas combinan ambas técnicas, de construcción y mejora, en una sola heurística. Muchas de las heurísticas de las encuadradas únicamente en mejora tienen ciertas características de construcción que posibilitarían encuadrarlas en este punto, (Scriabin y Vergin 1985),(Kusiak y Heragu 1987).

1.2.2.3.3 Metaheurísticas

Llegó un momento, a finales de los años 80, en el que las heurísticas propias del problema de distribución en planta llegaron a un punto en el que no se producían avances significativos o aparecían nuevas heurísticas que aceleraran el proceso de optimización del problema. El término metaheurística quedó acuñado por Glover, que en su artículo de presentación de la búsqueda tabú (*Tabú Search*), decía que la metaheurística es:

“...una heurística de nivel más alto...”

(Glover 1986)

En cualquier caso antepone el prefijo “meta-” a la palabra heurística, define bien a las claras el objetivo de estas técnicas, pues implica la idea de ir “*mucho más lejos*” o llevar “*a un nivel superior*” las heurísticas anteriormente citadas. En otra definición más actual y completa:

“...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.”

(Osman y Kelly 1996)

Por tanto, una metaheurística es una estrategia que guía el proceso de búsqueda de soluciones a un problema determinado, que generalmente incluye una serie de heurísticas subordinadas. Además las características que la diferencian de una heurística son que:

- Admiten descripciones a nivel abstracto (son técnicas de alto nivel).
- Son de uso genérico (no específicas para un tipo de problema, debiéndose particularizar para cada problema).

En este tipo de técnicas se debe mantener el equilibrio entre dos aspectos de gran importancia, que no están presentes en las heurísticas precedentes, que se centraban únicamente en una zona del espacio de soluciones del problema. Se debe encontrar un equilibrio entre *diversificación* e *intensificación*.

La *diversificación* se puede caracterizar como la cantidad de esfuerzo empleado en la búsqueda de regiones distantes a la de búsqueda actual. Esta característica fomenta la exploración de nuevas zonas del espacio de soluciones (líneas rojas en la Figura 1.2.15).

La *intensificación* es la cantidad de esfuerzo empleado en la búsqueda en la región actual. Esta característica explota la búsqueda en el entorno de la solución actual (líneas azules en la Figura 1.2.15).

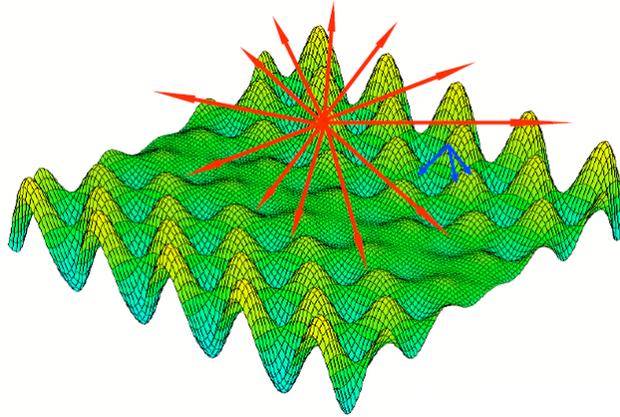


Figura 1.2.15 Estrategias de diversificación/intensificación sobre el espacio de soluciones.

Existen diferentes formas de clasificar las metaheurísticas atendiendo a distintos criterios, a continuación se describen brevemente las distintas clasificaciones encontradas en la bibliografía, recogidas de (Blum y Roli 2003).

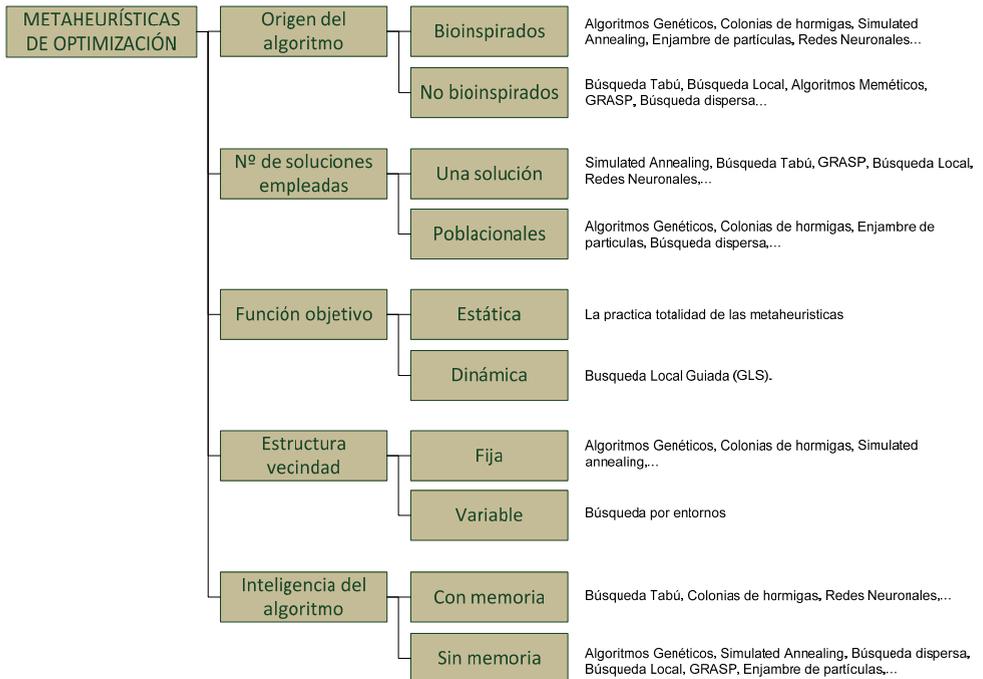


Figura 1.2.16 Clasificación de las Metaheurísticas, a partir de (Blum y Roli 2003).

La mayor parte de las metaheurísticas son **bioinspiradas**, y sus fundamentos básicos se basan en algún proceso o mecanismo que se puede encontrar en la naturaleza, bien sea el comportamiento social de algunos animales (colonias de hormigas, enjambres de abejas..), la forma en la que se enfrían los metales (Simulated Annealing), o los mecanismos de combinación genética (algoritmos genéticos). También se pueden encontrar algoritmos que no tienen su fundamento en ningún aspecto de la naturaleza o del comportamiento social (**no bioinspiradas**) como pueden ser la búsqueda dispersa, búsqueda tabú...

La clasificación más interesante y que adoptan un mayor número de autores es la que diferencia a las metaheurísticas en función del número de soluciones que se emplean en el proceso de optimización. Por un lado están las metaheurísticas que se denominan **de trayectoria**, es decir se maneja una solución que se va mejorando y es la que recorre el espacio de soluciones, buscando el mínimo global. Dentro de este grupo se enmarcan técnicas como el Simulated Annealing, búsqueda tabú, búsqueda local, GRASP... Por otro lado están las técnicas **poblacionales**, que emplean un número de soluciones elevado que se van combinando y buscan los mínimos globales de una forma colectiva. Ahí se pueden enmarcar las técnicas de algoritmos genéticos, meméticos, colonias de hormigas, enjambres de partículas....

Otra de las clasificaciones mostradas en la figura es en función del tipo de función empleada, aunque la práctica totalidad de metaheurísticas tienen una **función objetivo estática**, es decir con una formulación y objetivos fijos a lo largo del proceso de optimización. Por otro lado están las metaheurísticas cuya **función objetivo es variable**, y se adapta según avanza el proceso de optimización (búsqueda local guiada, GLS).

La estructura de la vecindad (aquellas soluciones accesibles desde la solución actual mediante una pequeña variación de alguna de las variables) también es un criterio que se usa para realizar la clasificación de las diferentes metaheurísticas. Por un lado están aquellas que emplean una estructura de la **vecindad fija** (algoritmos genéticos, colonias de hormigas..) y por otro lado están aquellas que admiten una estructura de la **vecindad variable** (búsqueda por entornos, Simulated Annealing).

La clasificación por la inteligencia del algoritmo diferencia aquellas metaheurísticas, que por su estructura son capaces de mantener un historial de la búsqueda realizada y por tanto se puede decir que son **metaheurísticas con memoria**, dentro de este grupo se pueden enmarcar la búsqueda tabú, las colonias de hormigas, algunos tipos de redes neuronales... el resto de técnicas que no son capaces de "recordar" el proceso de búsqueda se enmarcan en el grupo de **metaheurísticas sin memoria**.

Otros autores, como (van Camp, Carter y Vanelli 1991) prefieren seguir la clasificación mostrada en la Figura 1.2.17 que fue propuesta por (Melian, Moreno Pérez y Moreno Vega 2003), donde se pueden ampliar más conceptos acerca de las metaheurísticas y su clasificación.

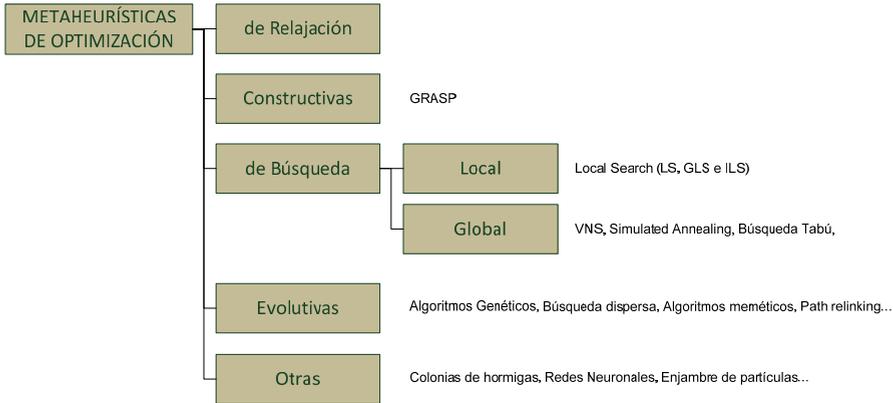


Figura 1.2.17 Clasificación de metaheurísticas de (Melian, Moreno Pérez y Moreno Vega 2003).

Numerosos autores han empleado metaheurísticas para la resolución del problema de distribución en planta. El número de publicaciones que han aparecido en los últimos años es muy numeroso (más de un centenar hasta 2004, tal y como cita (Diego-Más 2006), frente a una veintena de heurísticos y una treintena de exactos), aunque la mayor parte de ellos se centran en el problema monobjetivo, que queda alejado del propósito del presente trabajo. Tampoco se considera que sea objeto del presente trabajo la descripción del modo de funcionamiento de todas las metaheurísticas que se han utilizado para la resolución del problema, remitiendo a la tesis doctoral de (Diego-Más 2006) o al reciente artículo de revisión de (Drira, Pierreval y Hajri-Gabouj 2007) para más información sobre las metaheurísticas aplicadas al problema monobjetivo de distribución en planta.

En el capítulo 4 se describen con precisión las diferentes metaheurísticas aplicadas al problema de distribución en planta multiobjetivo, que es el objeto de la presente tesis doctoral.

Por tanto, de esta fase del SLP se obtiene una solución o un conjunto de soluciones (en la aproximación multiobjetivo del problema) que tienen un mejor diagrama de bloques atendiendo a uno o varios criterios.

2 ASPECTOS GEOMÉTRICOS DEL PROBLEMA DE DISTRIBUCIÓN EN PLANTA

Una vez conocida la naturaleza del problema que se va a abordar en el presente trabajo, se procede a describir todas las características geométricas que se deben considerar en su modelización.

En el presente capítulo se profundiza en las diferentes aproximaciones que, desde el punto de vista geométrico, se han realizado al problema de distribución en planta de establecimientos industriales. Estos aspectos son de gran importancia, pues el desarrollo de la posterior mecánica de optimización queda condicionada a la forma en la que se considera la geometría de la planta. Para establecer una formulación del problema se requiere que fije un modelo geométrico de representación del espacio de la distribución en planta a optimizar. Por tanto, el objetivo fundamental es determinar el soporte sobre el que se van a construir todas las soluciones en fases posteriores.

En primer lugar se consideraran los distintos modelos de soporte empleados en la bibliografía, tanto los topológicos, que plasman la resolución del problema mediante teoría de grafos y los geométricos. Entre los modelos geométricos se diferenciarán los diferentes problemas de optimización a los que dan lugar, en función del número de dimensiones que se consideren en la resolución del mismo.

Una vez fijado el modelo geométrico a emplear (modelo geométrico de dos dimensiones) se abordarán cuestiones relativas a cómo se considera el espacio a la hora de realizar la implantación de las actividades sobre el mismo. Se describen los modelos continuos y discretos que se han empleado en las referencias aplicadas al problema de distribución en planta de dos dimensiones (FLP).

Otros aspectos a fijar en el presente capítulo son los relativos al recinto sobre el que se colocarán las actividades, debiendo fijar tanto las dimensiones como la orientación del mismo. La dimensión del recinto debe tener capacidad para albergar el conjunto de actividades, la forma generalmente es fija, aunque podría considerarse variable con el fin de determinar la más idónea. Las dimensiones del recinto pueden venir impuestas por condiciones de la parcela disponible en la zona en la que se vaya a implantar la empresa.

Por último se seleccionará la métrica que se empleará para evaluar el coste de cada una de las soluciones, aspecto fundamental para la fase de optimización. La métrica utilizada para medir la distancia permite introducir en la fase de diseño conceptual o *block layout* aspectos relacionados con el sistema de manutención y con la distribución de detalle. Cada sistema de manutención tiene asociada una métrica de acuerdo con la trayectoria del flujo y el principio y final de un recorrido se definen con precisión en la distribución de detalle.

2.1 MODELOS DE REPRESENTACIÓN ESPACIAL

Una de las primeras decisiones fundamentales a tomar a la hora de abordar el problema de distribución en planta de establecimientos industriales es el relativo al modelo de representación espacial que se va a emplear. En la bibliografía se pueden encontrar dos líneas claramente diferenciadas en este punto del problema:

1. La primera línea de trabajo emplea un modelo espacial **topológico**, basado en teoría de grafos, tanto para el planteamiento como para la resolución del problema. Este enfoque es muy empleado en aquellas referencias en las que se utilizan objetivos cualitativos.
2. La segunda emplea un modelo espacial **geométrico** a la hora de colocar las actividades sobre el plano, o sobre el espacio. En esta línea es en la que se encuentran la mayor parte de los trabajos, por ello se dedicará un mayor nivel de detalle en este apartado.

En la Figura 2.1.1 se muestra una clasificación de los distintos modelos de representación espacial empleados en las distintas versiones del problema de implantación de industrias en la bibliografía consultada. Si se opta por los modelos geométricos se abre un amplio abanico de opciones en función del espacio empleado, ya sea unidimensional, en cuyo caso el problema será un SRLP (*Single Row Layout Problem*), bidimensional, al que se denomina FLP (*Facility Layout Problem*) y el caso de más de dos dimensiones. Una línea con mucha pujanza en la actualidad es emplear dos dimensiones y media, integrando varias plantas iguales y ascensores entre ellas, el MFLP (*Multi Facility Layout Problem*) o bien una formulación que emplee plenamente las 3 dimensiones. En cada uno de los modelos geométricos se debe decidir a su vez si se va a emplear una representación espacial continua o discreta, pues la formulación del problema varía sensiblemente en ambos casos.

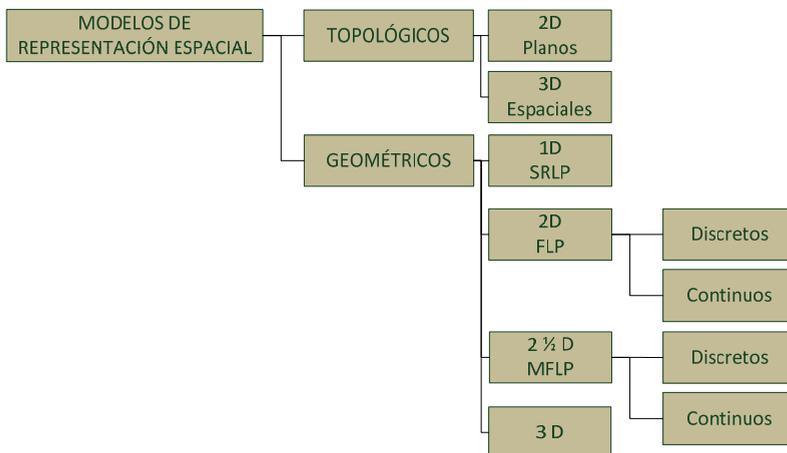


Figura 2.1.1 Clasificación de los modelos de representación espacial.

2.1.1 Modelos topológicos

Las aproximaciones al problema de distribución en planta que emplean modelos de representación espacial topológicos, no persiguen encontrar una distribución exacta de cada una de las n actividades del problema, sino más bien su posición relativa. El diagrama final deberá satisfacer una serie de aspectos que tienen que ver con la necesidad de proximidad o lejanía de actividades, así como por el flujo de materiales entre actividades.

Si las restricciones espaciales son más estrictas y solo se permite la colocación de actividades en un plano de trabajo, se obtiene un modelo de dos dimensiones, que es el más extendido en la bibliografía. Sin embargo es posible extender el problema a tres dimensiones si se elimina la restricción de planaridad.

Por tanto, se persigue construir un diagrama relacional de actividades y/o recorridos de modo que no se produzcan cruzamientos (principio de circulación) y sean adyacentes las actividades con máxima relación o estén separadas las incompatibles (principio de la mínima distancia, principio de la seguridad y confort y principio de integración).

Como paso previo a la materialización de alternativas (etapa de síntesis), tanto (Muther 1968) como (Buffa 1955) proponen, tal y como se vio en el capítulo anterior, realizar una representación a través de un grafo, para plasmar las interacciones existentes entre las diversas actividades que componen la planta (representando las mismas como puntos). Muther denomina al diagrama resultante "Diagrama Relacional de Recorridos y/o Actividades" y Buffa "Diagrama Esquemático Ideal".

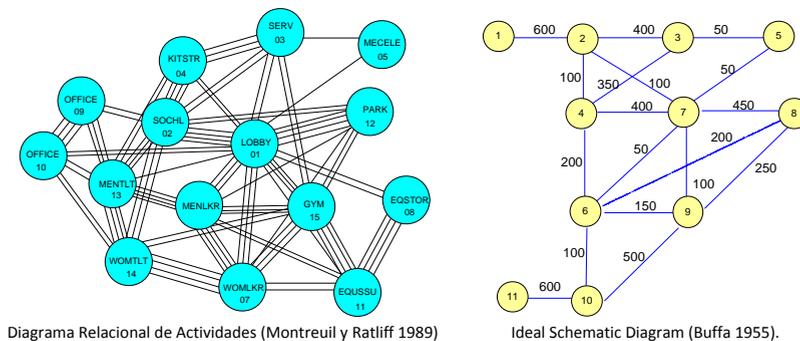


Figura 2.1.2 Representaciones de diagramas de relación (Santamarina 1995).

(Seppänen y Moore 1970) inician esta nueva línea de métodos de generación de distribuciones en planta de recintos industriales (*layouts*) basados en técnicas de teoría de grafos, que ha llegado a alcanzar un considerable desarrollo.

Conviene destacar que la utilización de estas técnicas supone un enfoque radicalmente diferente al adoptado por la mayor parte de los métodos de generación de *layouts*, puesto que su origen radica en las metodologías (manuales) propuestas por Buffa y Muther.

2.1.1.1 Aspectos básicos de la teoría de grafos

Los primeros antecedentes históricos del uso de la *teoría de grafos* como metodología de resolución de problemas, datan de 1736 cuando Euler los utilizó para resolver el problema clásico de los puentes de Koenigsberg.

Un grafo G está formado por un conjunto de nodos, denominados vértices (v_i), conectados por arcos, denominados aristas ((v_i, v_j)). El grafo se representa como $G=(V,A)$, donde V es el conjunto de los vértices v_i y A el conjunto de las aristas (v_i, v_j) .

Si (v_i, v_j) es una arista de $A(G)$, entonces se dice que los vértices v_i y v_j son adyacentes, y que la arista (v_i, v_j) es incidente en los vértices v_i y v_j .

En el caso de que las aristas no tengan un sentido definido, es decir queden identificadas por un par no ordenado de vértices, se dice que el grafo es *no dirigido*. En caso contrario se trata de un *grafo dirigido*.

El conjunto de grafos que tienen un mayor interés en la resolución del problema de distribución en planta es el de los no dirigidos, ya que los métodos que utilizan la teoría de grafos responden habitualmente a las relaciones representadas en el diagrama relacional de actividades de Muther, en el que se expresa la conveniencia de que dos actividades ocupen posiciones adyacentes en el layout.

G' es un *subgrafo* de G si y solo si: $A(G') \subseteq A(G)$ y $V(G') \subseteq V(G)$. En la Figura 2.1.3 se puede observar un grafo (izquierda) con dos subgrafos del mismo (centro e izquierda).



Figura 2.1.3 Grafo y subgrafos.

El número de pares no ordenados distintos en un grafo con n vértices es $\frac{1}{2} \cdot n \cdot (n-1)$. Un grafo no dirigido de n vértices con $\frac{1}{2} \cdot n \cdot (n-1)$ aristas se dice que es *completo*.

Un *camino*, del vértice v_p al vértice v_q , en un grafo G , es una secuencia de vértices $v_p, v_{i_1}, v_{i_2}, \dots, v_{i_n}, v_q$, tal que $(v_p, v_{i_1}), (v_{i_1}, v_{i_2}), \dots, (v_{i_n}, v_q)$ son aristas del grafo G . La *longitud* de un camino es el número de aristas del mismo. Un *camino simple* es un camino en que todos sus vértices, excepto posiblemente el primero y el último, son distintos. Un *ciclo* es un camino simple cuyos vértices inicial y final son el mismo.

En un grafo no dirigido G , dos vértices v_i y v_j se dice que son *vértices conexos* si existe un camino en G de v_i a v_j . Un grafo no dirigido se dice que es un *grafo conexo* si para cada par de vértices distintos v_i, v_j de $V(G)$ existe un camino de v_i a v_j en G .

Las áreas que quedan definidas por cada ciclo de aristas de un grafo se denominan *caras*. La región exterior al grafo también se considera una cara, pero como una cara infinita.

Un grafo G es un *grafo ponderado* si sus aristas tienen pesos asociados que pueden ser utilizados como parámetros de coste o beneficio.

Otro concepto importante es el de *grafo planar*, se dice que un grafo es planar si, al menos, tiene una representación bidimensional en la que sus aristas sólo se intersectan en los vértices. En la Figura 2.1.4 se puede observar el concepto de planaridad. Además se define como *grafo planar maximal* a aquel grafo planar que deja de serlo si se le añade una arista más. Se dice que un grafo es *planar ponderado maximal*, si es un grafo planar maximal y sus aristas tienen los mayores pesos asociados posibles.

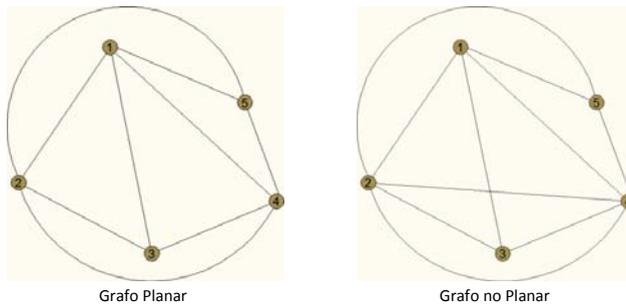


Figura 2.1.4 Ejemplo de planaridad de un grafo.

En 1736 Euler estableció la conocida ecuación que liga el número de caras, vértices y aristas en un grafo conexo planar, y que tiene por expresión:

$$v - a + c = 2 \tag{2.1}$$

Donde: a = número máximo de aristas del grafo.
 c = número máximo de caras del grafo.
 v = número de vértices del grafo.

En un problema de distribución en planta en el que existen n actividades (en este caso vértices), pueden existir como máximo $1/2 \cdot n \cdot (n-1)$ relaciones entre ellas.

Sin embargo, para que el grafo sea planar, la condición de planaridad exige que el máximo número de relaciones que se pueden respetar sea de $3n-6$, lo que muestra la imposibilidad de cumplir todos los requisitos relacionales (aumentando el incumplimiento a medida que crece el número de actividades, ver Figura 2.1.5)

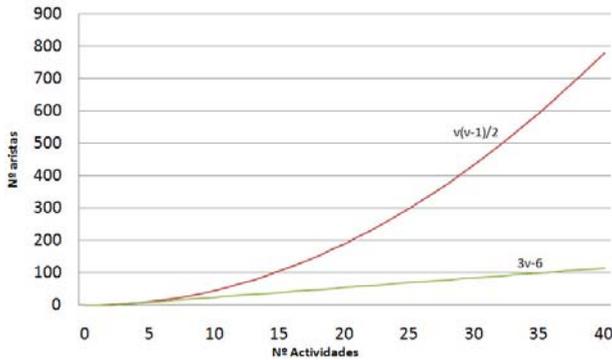


Figura 2.1.5 Incumplimiento relacional consecuencia de la planaridad.

Asociado a cada grafo planar G existe un grafo dual G' que también es planar. El grafo dual planar G' se construye colocando un punto en cada cara del grafo planar G , incluyendo la cara infinita, y conectando con una arista los pares de puntos cuyas caras tienen arista común. Estos puntos se convierten en los vértices del grafo dual y las líneas que los conectan en sus aristas. El número de vértices del grafo dual de un grafo planar es igual al número de caras del grafo planar.

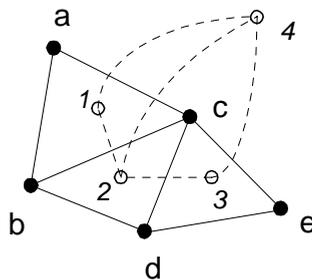


Figura 2.1.6 Grafo dual (Contero Gonzalez 1995).

Un concepto también muy empleado en teoría de grafos es el concepto de *árbol*. Se define un árbol como un grafo conexo que no tiene ciclos, siendo un tipo especial de árbol el denominado *árbol de expansión*, que se define, dado un grafo G , como un subgrafo en forma de árbol que contiene a todos los vértices de G .

A la vista de esta definición, es evidente que asociado a un grafo existen para el mismo, diferentes árboles de expansión. De todos ellos, es de especial interés para su aplicación a la resolución de problemas de distribución en planta, el denominado *árbol de expansión maximal*, (Figura 2.1.7) que corresponde en el caso de un grafo ponderado G a aquel árbol de expansión que maximiza la suma de los pesos asociados a sus aristas.

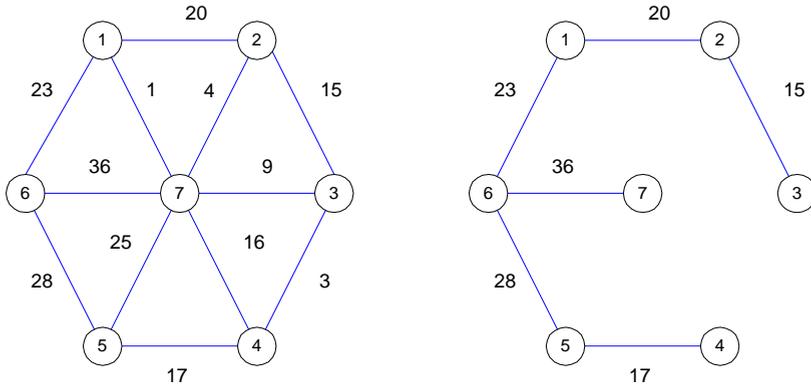


Figura 2.1.7 Árbol de expansión maximal.

El tamaño del espacio de configuraciones, es decir, el del número de posibles grafos planares construibles (N) para un conjunto de n actividades asciende, tal y como señala(Santamarina 1995) a:

$$N = C_{n(n-1)/2}^{3n-6} \quad (2.2)$$

con este modelo topológico la formulación del problema en dos dimensiones (plano) es:

$$\text{MAX } G(a_i, r_{ij}) \quad (2.3)$$

s.t.:

$$G(a_i, r_{ij}) \text{ planar} \quad (2.4)$$

Si se quiere extender esta formulación al problema de distribución en planta en tres dimensiones (como puede ocurrir por ejemplo en el caso de plantas petroquímicas) se debe eliminar la restricción (2.4) para permitir que las actividades se coloquen en altura.

2.1.1.2 Aplicación al problema de distribución en planta

Para la obtención del *block layout* mediante teoría de grafos se deben abordar tres fases:

1. Obtener el Grafo Planar Ponderado Maximal (GPPM)

En esta primera fase las actividades se suponen sin área, y el objetivo es obtener el grafo planar ponderado maximal a partir del diagrama relacional de actividades, el método heurístico de construcción del Diagrama Relacional de Recorridos y/o Actividades (propuesto por Muther) persigue la ordenación topológica de las actividades. El objetivo es encontrar un grafo en el que se muestren las relaciones existentes entre las diferentes actividades intentando que no existan cruzamientos (Principio de Circulación), al menos entre las líneas que muestran las relaciones de mayor intensidad (Principio de la Mínima Distancia), lo que en teoría de grafos se denomina un *Grafo Planar Ponderado Maximal*.

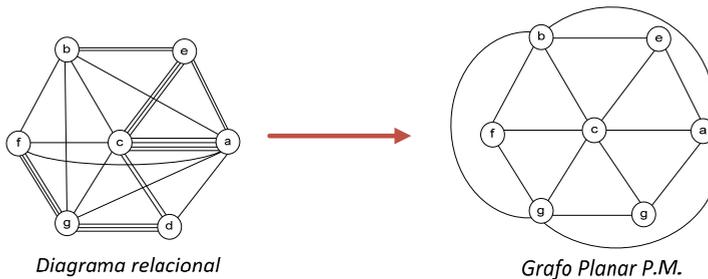


Figura 2.1.8 Transformación en un G.P.P.M.(Santamarina 1995).

En (Santamarina 1995) se puede encontrar algunas referencias de algoritmos desarrollados para la obtención del GPPM a partir de la tabla relacional, bien sea con comprobación de la condición de planaridad, como en (Carrie et al. 1978) o (Foulds y Robinson 1976) o sin comprobación de la planaridad, como en (Foulds y Robinson 1978) (Green y Al-Hakim 1985) o (Boswell 1992).

2. Obtener el grafo dual

Una vez obtenido el GPPM se obtiene el grafo dual, colocando un vértice en cada una de las caras del grafo, incluyendo en la cara exterior. El proceso es el mostrado en la Figura 2.1.6.

3. Obtener el layout de bloques

En esta última fase, se incorporan los aspectos geométricos (área y forma), obteniendo a partir del grafo dual la distribución del layout de bloques. En esta línea, se pueden destacar las aportaciones de (Hassan y Hogg 1989) y (Hassan y Hogg 1991).

2.1.2 Modelos geométricos

2.1.2.1 Modelos de una dimensión (SRLP)

La opción más simple para la modelización del problema de distribución en planta es considerarlo como un problema de una sola dimensión, donde las actividades se colocan en una fila, sin tener en cuenta la dimensión Y, generando de esta forma un recinto con muchos espacios vacíos.

(Simmons 1969) propone la resolución del problema de distribución en planta como un modelo de secuenciación y lo resuelve mediante el método de ramificación y acotación (*branch and bound*) para obtener soluciones eficientes. Visualiza el problema como un ordenamiento del conjunto de actividades de distinta área (no uniformes) pero conocidas, y va colocando las mismas en una sola dimensión, (una detrás de otra), al final obtiene las posiciones de las actividades en esa cadena. La secuencia que menor coste obtenga será el óptimo. El algoritmo no contempla restricciones de colocación de las actividades en la línea.

El tamaño del espacio de soluciones (N) del problema de n actividades con esta formulación será:

$$N = n! \quad (2.5)$$

En (Heragu 1997) se clasifica este tipo de problemas para el caso en continuo, como “problemas de distribución de planta unidimensionales” (*Single-Row Layout Problem, SRLP*).

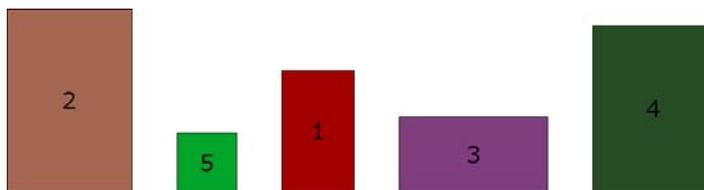


Figura 2.1.9 Arreglo unidimensional (SRLP).

2.1.2.2 Modelos de dos dimensiones (FLP)

El segundo grupo de aproximaciones al problema son aquellas que emplean dos dimensiones para representar el diagrama de bloques de una planta industrial. Las actividades, tienen en este caso ancho y largo y deben posicionarse sobre el recinto que las alberga sin superposición, aprovechando de esta forma la totalidad de la parcela.

En general, cada actividad queda definida por sus dos dimensiones y por la posición (X,Y) del centro de gravedad de la misma, aunque la forma en la que se trata el espacio pueda ser diferente, tal y como se comentará en este punto.

El problema de distribución en planta en 2D es lo que se conoce como el FLP (*Facility Layout Problem*) diferenciándose entre el problema del layout de bloques (*block layout*) y la fase de diseño de detalle (*detail layout*). En el primero solo se consideran las dimensiones de las actividades y no el punto de entrada y salida de materiales ni la distribución interior de cada actividad o el flujo interno, que se dejan para la segunda fase.

En la Figura 2.1.10 se muestran los distintos modelos geométricos en 2D aplicados en la resolución del problema de distribución en planta, haciendo una clara diferencia entre aquellos que emplean un modelo discreto y los que utilizan un modelo continuo.

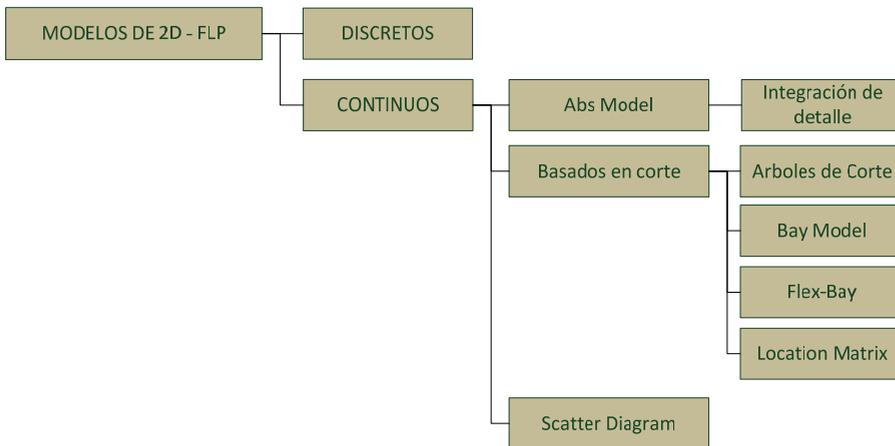


Figura 2.1.10 Clasificación de los modelos geométricos en 2D.

A continuación se desglosan y comentan las diferentes aproximaciones realizadas mediante los modelos geométricos discreto y continuo con las diferentes variantes de cada una de ellas.

2.1.2.2.1 Modelos discretos

La representación geométrica empleando un modelo discreto se muestra en la Figura 2.1.11. Sea un dominio $D(A)$ de geometría conocida y área A , donde deben ubicarse, sin superposición, n actividades industriales de área a_i y geometría libre. Por geometría libre, se entiende que no existe ninguna forma, ni coeficiente de aspecto definido a priori para cualquiera de las actividades que restrinja su forma geométrica. Cada una de las n actividades, queda definida por $D_i(a_i)$.

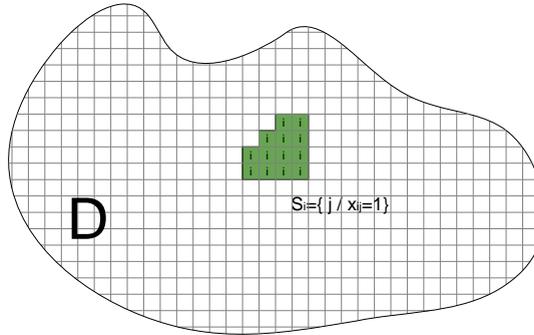


Figura 2.1.11 Discretización de un dominio y su representación.

El dominio $D(A)$ se discretiza en una retícula de c subdominios elementales de área a , de tal forma que $c \cdot a = A$, produciéndose la siguiente transformación:

$$\begin{aligned}
 D(A) &\longrightarrow D(c, a) \\
 D_i(A_i) &\longrightarrow D_i(c_i, a) / A_i = c_i \cdot a
 \end{aligned}
 \tag{2.6}$$

Como consecuencia de la discretización, el dominio D se transforma en un conjunto de c casillas o ubicaciones, sobre las que se deben asignar las n actividades. A cada actividad i , se le asocia un conjunto de celdas elementales S_i sobre el que se distribuye la actividad. A este conjunto de celdas elementales se le denomina conjunto de asignación. Si la formulación del problema es la de un problema cuadrático de asignación (QAP), cada actividad ocupa una única casilla, por tanto no es necesario emplear el conjunto de asignación.

Como resultado de la discretización del dominio se puede establecer una matriz de distancias $\underline{d}(d_{kl})$ que recoge las distancias existentes entre las diferentes celdas en las que ha sido discretizado el dominio D y que recoge la geometría del mismo.

El tamaño del espacio de configuraciones posibles del dominio discretizado es, en el caso de permitir la desagregación de las actividades al implantarse sobre el mismo:

$$N = C_c^{c_1} \prod_{i=2}^n C_{c_i}^{c_i} = \frac{c!}{\prod_{i=1}^n c_i!} \quad (2.7)$$

Donde: n es el número de actividades.
 c el número de celdas de la discretización.
 c_i el número de celdas de la actividad i .

Formulación del problema

Para facilitar la formulación de la función de coste, se emplea el concepto de variable de asignación x_{ik} , que adopta los siguientes valores:

$$x_{ik} = \begin{cases} 1 & \text{si la actividad } i \text{ ocupa la casilla } k\text{-ésima.} \\ 0 & \text{si la actividad } i \text{ no ocupa la casilla } k\text{-ésima.} \end{cases} \quad (2.8)$$

Las variables de asignación permiten establecer las distancias existentes entre dos actividades (i y j) de la configuración, mediante la siguiente expresión:

$$d_{ij} = \frac{1}{c_i \cdot c_j} \sum_{k=1}^c \sum_{l=1}^c d_{kl} \cdot x_{jl} \cdot x_{ik} \quad (2.9)$$

La formulación monobjetivo más simple del problema, es la que viene impuesta por la función de coste de instalación de las actividades en una posición y el coste de mantenimiento (derivado del flujo de materiales entre actividades), que puede ser expresada mediante:

$$MHC = \sum_{i=1}^n b_i + \sum_{i=1}^n \sum_{j=1}^n w_{ij} \cdot d_{ij} \quad (2.10)$$

Donde b_i es el coste de instalación de la actividad i -ésima en su posición actual y w_{ij} es la intensidad relacional entre las actividades i y j , que establece el coste de movimiento de productos entre dos actividades por metro de distancia. El coste de instalación de actividades suele ser considerado nulo en el problema 2D, pues no existe un coste adicional por colocar una actividad en una posición determinada. Este coste puede variar en el caso de colocar actividades muy pesadas en altura o si se consideran cuestiones ambientales de la planta, tales como iluminación o ventilación.

Considerando el dominio discreto y la función de coste expresada en términos de variables de asignación, la formulación del problema de distribución en planta con actividades de área variable que se va a utilizar es la siguiente:

$$\text{Min } C = \sum_{i=1}^n \sum_{j=1}^n \sum_{k=1}^c \sum_{l=1}^c \frac{W_{ij}}{C_i \cdot C_j} \cdot d_{kl} \cdot x_{ik} \cdot x_{jl} \quad (2.11)$$

s.t.

$$\sum_{k=1}^c x_{ik} = A_i \quad (2.12)$$

$$\sum_{i=1}^n x_{ik} = 1 \quad (2.13)$$

$$x_{ik} = x_{ik}^2 \quad (2.14)$$

La restricción (2.12) controla que cada actividad i este compuesta por un número de casillas tal que se alcance el área necesaria para la instalación (A_i). La restricción (2.13) vela por la no superposición de actividades en una misma casilla, por último, (2.14) no es una restricción como tal, sino que es la propia definición de la variable de asignación.

A estas restricciones, habría que añadirle una cuarta, que velara por la no disgregación de las actividades a medida que se van colocando sobre el dominio. El problema es que esta restricción es dependiente de la técnica de relleno que se emplee, pudiéndose dar dos casos:

- *La técnica de relleno no controla la agregación:* Esta situación se da, por ejemplo, en técnicas de relleno tipo ALDEP oscilatorio con anchos de banda distintos de la unidad, en cuyo caso hay que establecer algún tipo de algoritmo de control de la disgregación, como pueden ser el algoritmo de la matriz de conectividad propuesto por (Contero Gonzalez 1995).
- *La técnica de relleno controla la agregación:* Esta situación se da por ejemplo en el caso de utilizar curvas de relleno (SFC), que ocupan el recinto discretizado de forma continua, garantizando la no rotura de las actividades a medida que se colocan.

Algunas de las **técnicas de relleno** utilizadas en la construcción de soluciones en el caso de dominios discretos de entre las que se pueden encontrar en la bibliografía son PLANET, ALDEP o las curvas de relleno (SFC).

ALDEP

La técnica de relleno que se ha empleado con mayor profusión por los autores que utilizan un modelo geométrico discreto es *ALDEP* (*Automated Layout Design Program*) que fue propuesto por (Seehof y Evans 1967). Los autores presentan el algoritmo de construcción y también un proceso de mejora basado en el intercambio de actividades. El área del recinto es fija, así como el área de las actividades.

El barrido a lo largo del recinto es oscilatorio, pudiéndose diferenciar diferentes estrategias, en función de que el mismo se produzca en el eje X, en el eje Y, en ambos ejes o bien en espiral. En capítulos posteriores se desarrollarán aspectos importantes de esta técnica como el ancho de banda del barrido, que es la principal fuente de los problemas de agregación.

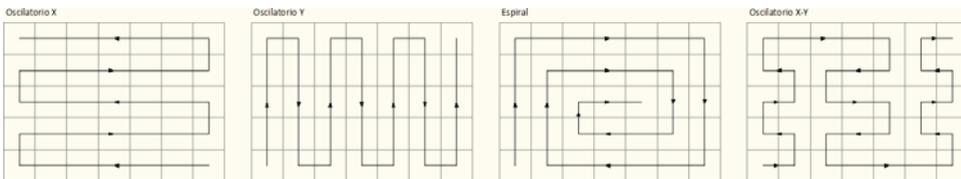


Figura 2.1.12 Distintas técnicas de colocación de ALDEP.

PLANET

Plant Layout Analysis and Evaluation Technique fue propuesto en (Apple y Deisenroth 1972). En este algoritmo el área del recinto es variable y tanto la forma como la dimensión de las actividades es conocida. El método para posicionar las actividades se realiza en base a un ordenamiento de prioridad de entrada y al coste asociado por el flujo de material entre actividades. La colocación de las actividades sigue una espiral partiendo del centro del recinto.

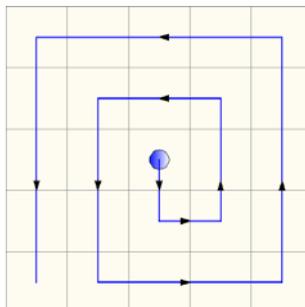


Figura 2.1.13 Rutina de colocación en espiral de PLANET (Apple y Deisenroth 1972).

CURVAS DE RELLENO (SFC)

Una evolución a la técnica ALDEP es la construcción de soluciones mediante curvas de relleno del espacio, o SFC (*Space Filling Curves*). Esta técnica, ampliamente estudiada por los matemáticos, fue empleada por primera vez en un problema de optimización en (Bartholdi III y Platzman 1982), donde es aplicada para la resolución del problema TSP (problema del viajante de comercio).

La primera aplicación de esta técnica de relleno al problema de distribución en planta se puede encontrar en el algoritmo MULTIPLE, propuesto por (Bozer, Meller y Erlebacher 1994). En el mismo, los autores describen la SFC como "una línea continua que une todas las casillas de un recinto (discretizado) sin producir disgregación de la actividad, pues el tránsito de un punto siempre es hacia otra casilla vecina".

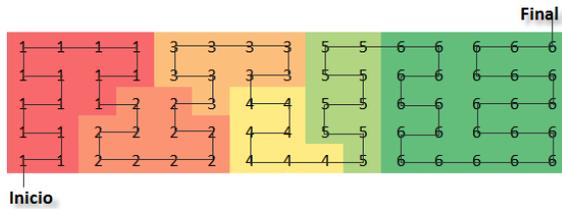


Figura 2.1.14 Ejemplo de SFC, adaptado de (Bozer, Meller y Erlebacher 1994).

En un edificio rectangular, sin actividades fijas o zonas vetadas, la SFC puede obtenerse mediante un método recursivo que da lugar a la denominada "curva de Hilbert", que fue propuesta por el autor homónimo en 1891. Una descripción de este método recursivo puede encontrarse en el apéndice del artículo de Bozer y Meller, para casos en los que el número de celdas horizontales (n_a) sea igual a 2^n .

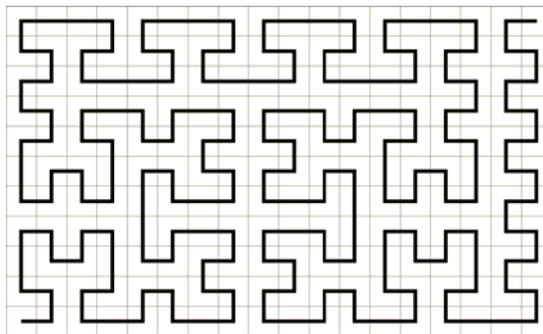
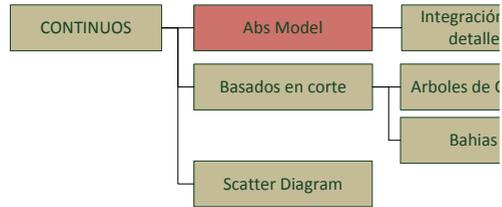


Figura 2.1.15 SFC generada mediante el método sugerido en (Bozer, Meller y Erlebacher 1994).

2.1.2.2 Modelos continuos

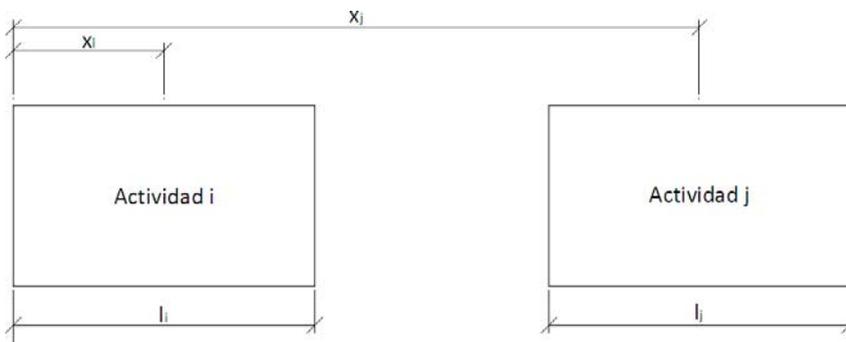
Otro grupo de autores son aquellos que emplean un modelo geométrico continuo, sobre el que se implantan las actividades. Sin embargo, no todos los autores formulan en problema de la misma forma, pudiendo distinguirse tres grandes grupos de aproximaciones:



MODELO ABSMODEL

En primer lugar se destaca la familia de modelos geométricos desarrollados en (Hera Kusiak 1991) y (Heragu y Kusiak 1992), que permite realizar una comparación respecto a la formulación establecida en los modelos geométricos discretos. Casi simultáneamente (Tam y Li 1991) se propone un modelo del mismo tipo, aunque se seguirá con la nota introducida por Heragu.

El modelo se denomina ABSMODEL, y evoluciona desde el 1, que define el problema de distribución en planta como un modelo de secuenciación en el cual las actividades se colocan una después de otra en forma lineal y no existe la restricción en la forma del espacio donde las actividades serán colocadas (se corresponde con el problema unidimensional comentado en la página 45). En este primer modelo, los autores consideran las actividades de forma cuadrada o rectangular y de orientación conocida. La Figura 2 muestra el esquema para la formulación de este modelo.



El segundo modelo, *ABSMODEL2*, es una evolución del anterior, y se adapta al problema QAP, en el que todas las actividades tienen la misma área (unitaria) y pueden ser dispuestas en dos dimensiones X e Y. Las actividades se consideran de forma cuadrada y sin holgura entre las mismas. Este modelo agrega restricciones del tamaño del recinto para asegurar que las actividades serán colocadas completamente en su interior. La Figura 2.1.17 muestra el formato para la formulación del modelo.

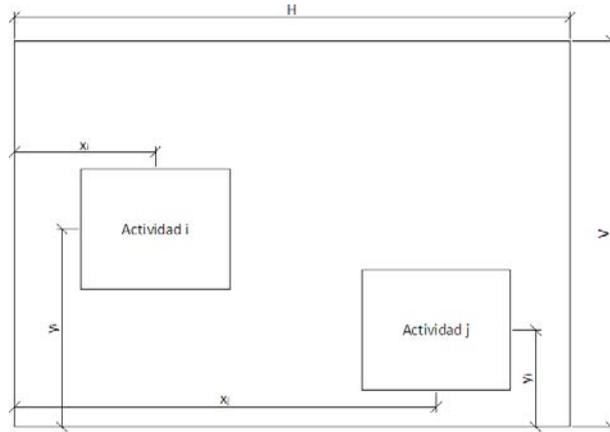


Figura 2.1.17 Características fundamentales del *ABSMODEL2* (Heragu 1997).

En el tercer modelo, el *ABSMODEL3*, se considera que cada actividad *i*, tiene a priori, una forma rectangular o cuadrada, definida por sus dimensiones y la posición de la misma queda definida únicamente por la posición de su centro de gravedad (x_i, y_i) . Por tanto las actividades no se sitúan de una manera compacta sobre el recinto, sino que existe una cierta holgura entre cada una de ellas. Este modelo geométrico es muy importante y ha sido empleado por numerosos investigadores en los últimos años.

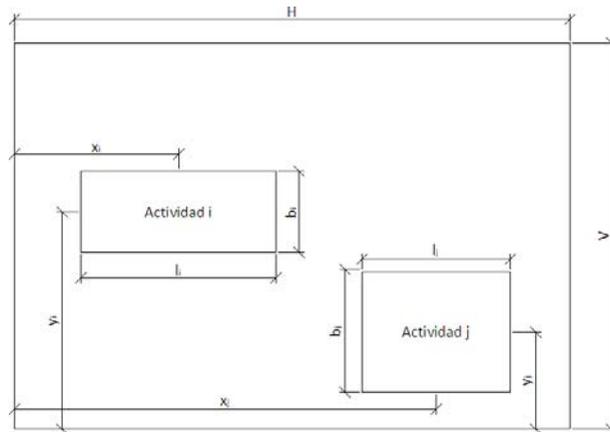


Figura 2.1.18 Características fundamentales del *ABSMODEL3* (Heragu 1997).

Formulación del problema

La función objetivo que habitualmente se formula cuando se emplea este modelo geométrico es de tipo cuantitativo y consiste en minimizar el coste total de manutención requerido por el flujo entre actividades, si se emplea el concepto de intensidad relacional entre actividades w_{ij} como el producto del coste de manutención (c_{ij}) por el flujo entre actividades (f_{ij}) es la siguiente:

$$\text{Min } C = \sum_{i=1}^{n-1} \sum_{j=i+1}^n w_{ij} (|x_i - x_j| + |y_i - y_j|) \quad (2.15)$$

s.t.

$$|x_i - x_j| \geq \frac{1}{2}(l_i + l_j) + d_{\min_{ij}}, \quad i=1, \dots, n-1 \quad j=i+1, \dots, n \quad (2.16)$$

$$|y_i - y_j| \geq \frac{1}{2}(b_i + b_j) + d_{\min_{ij}}, \quad i=1, \dots, n-1 \quad j=i+1, \dots, n$$

$$x_i + \frac{l_i}{2} \leq H \quad i=1, \dots, n \quad (2.17)$$

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

$$l_i \geq L_i \quad i=1, \dots, n$$

$$b_i = \frac{A_i}{l_i} \quad i=1, \dots, n \quad (2.18)$$

Las restricciones de este modelo geométrico son más complejas que las del modelo discreto, en todas ellas b_i y l_i son los largos y anchos de las i actividades:

Restricción de no superposición (2.16)

Las dos restricciones que se incorporan en este modelo, representan la condición de no superposición, de tal forma que se garantiza, que siempre existirá una distancia mínima, $d_{\min_{ij}}$ entre las actividades i y j .

Restricción de inclusión en el dominio (2.17)

Se introducen una serie de restricciones para garantizar que las actividades queden inscritas dentro de un rectángulo, que representa las dimensiones máximas del dominio, cuyas dimensiones horizontal y vertical, son H y V respectivamente.

Restricciones de aspecto y la orientación (2.18)

Otro tipo de restricciones que se pueden incluir, consideran el caso en que las actividades no sean rígidas (geometría variable), y sólo se conozca a priori el área A_i de cada una de ellas y su longitud mínima l_i .

Integración del diseño de detalle

En (Barbosa-Póvoa, Mateus y Novais 2001) se da un paso más al modelo ABSMODEL de Heragu integrando sobre el mismo la posibilidad de considerar el diseño de detalle, al incluir los puntos de entrada y salida de materiales de cada actividad.

Otra diferencia fundamental es que permite considerar actividades de formas irregulares, mediante la descomposición de las mismas en sub-actividades, tal y como se muestra en la Figura 2.1.19. los puntos de entrada y salida de la actividad global quedan definidos (o_{i1}, o_{i2}).

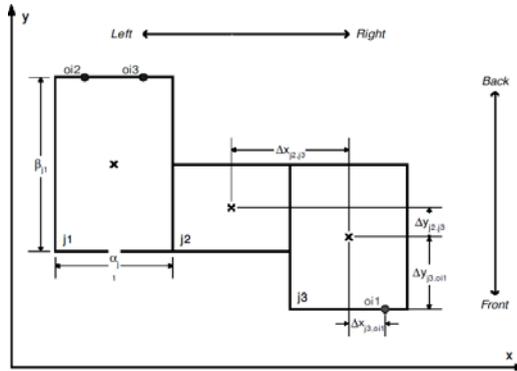


Figura 2.1.19 Descomposición en subactividades, de (Barbosa-Póvoa, Mateus y Novais 2001).

El modelo matemático propuesto emplea una formulación MILP (*Mixed Integer Linear Programming*) y se imponen una serie de restricciones para controlar por una parte aspectos relativos a las actividades, como son la Orientación (permitiéndose giros cada 90°), Descomposición (en subactividades conectadas entre sí), así como de Entrada y salida (posición de los puntos).

Y otra serie de restricciones que controlan aspectos de posición de las mismas sobre el recinto: Distancia entre actividades (controlando la holgura), No superposición, Seguridad (fijando un rango de distancias entre actividades) y Control de recinto.

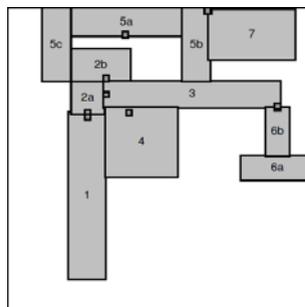
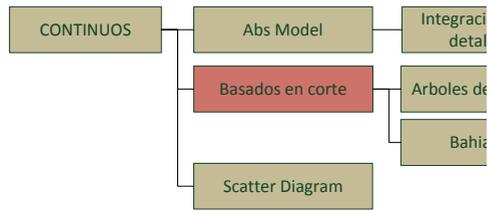


Figura 2.1.20 Ejemplo de solución de (Barbosa-Póvoa, Mateus y Novais 2001).



BASADOS EN CORTE

Un gran número de autores consideran el recinto sobre el que se va a implantar la distribución en planta como un elemento continuo sobre el que se realizan una serie de cortes para ir configurando la posición de las actividades sobre el mismo. Este grupo de modelos son los modelos *continual plane* o modelos basados en cortes.

La representación de la distribución mediante árboles de corte, tiene sus inicios a principios de los años 80 como se recoge en las referencias (Stockmeyer 1983), (Wong y Liu 1988) (Tam y Li 1992). Mediante esta técnica, la distribución se genera a base de dividir recursivamente el dominio de partida $D(A)$. Para ello, se definen una serie de operadores de corte, que indican las direcciones en que se efectúan los cortes. Lo habitual es utilizar dos direcciones perpendiculares entre sí (cortes verticales y horizontales, respecto a un sistema de referencia previamente definido) para dividir el dominio de partida, que a su vez puede tener cualquier geometría, como se puede observar en la Figura 2.1.21:

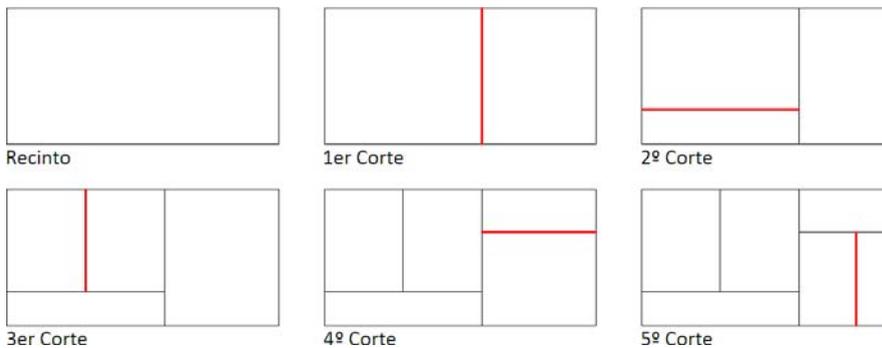


Figura 2.1.21 Geometría de árboles de corte.

Un elemento clave para aprovechar la calidad geométrica que se puede obtener con este tipo de representación es la correcta colocación de unas actividades respecto de otras. Para ello es necesario agrupar las actividades en base a su afinidad para poder decidir en qué actividades se deben colocar a cada uno de los lados del corte.

Las técnicas de agrupamiento estudian la afinidad entre actividades mediante la medida de las distancias existentes entre ellas. Para ello, se construyen unas matrices de distancias $d(d_{ij})$, cuyos elementos representan la distancia entre cada par de actividades, distancia que se calcula mediante el empleo de la intensidad relacional (w_{ij}) entre ambas actividades, y que como ejemplo se podría utilizar la de la siguiente expresión, (Tam y Li 1992):

$$d_{ij} = \frac{1}{1 + w_{ij} + w_{ji}} \quad (2.19)$$

Esta expresión fuerza a que las actividades más afines serán aquellas entre las que la intensidad relacional sea mayor. Conocida la matriz de distancias $d(d_{ij})$, se puede establecer un mecanismo de agrupamiento, que en el caso más sencillo, se iniciaría por agrupar las dos actividades entre las que exista la mínima distancia. Tras realizar este primer agrupamiento, de nuevo se recalcula la matriz de distancias, considerando el nuevo grupo creado como si fuera una actividad y recalculando sus distancias con el resto de actividades todavía no agrupadas

En el procedimiento de recalcado de las distancias se pueden utilizar diferentes métricas de la distancia; encadenamiento simple, completo, centroide, *group average*, etc...

Tomando las distancias definidas por el método *group average*, la distancia de cualquier actividad todavía no agrupada k a un grupo recién constituido por la fusión de dos actividades (o dos grupos de actividades) i y j , se puede calcular como:

$$d_{k(ij)}^2 = \frac{n_i}{n_i + n_j} d_{ki}^2 + \frac{n_j}{n_i + n_j} d_{kj}^2 \quad (2.20)$$

Donde:

- n_i es el número de actividades incluidas en el grupo i .
- n_j es el número de actividades incluidas en el grupo j .
- d_{ki} es la distancia entre la actividad k y el grupo i antes de la fusión.
- d_{kj} es la distancia entre la actividad k y el grupo j antes de la fusión.

Si existen n actividades se realizan $n-1$ agrupaciones. En cada una de ellas, se van agrupando las actividades o grupos de actividades que son entre sí, más afines.

Existen numerosas técnicas para determinar la forma de agrupar las actividades en clases homogéneas. Las técnicas de *clustering* (agrupamiento) de análisis multivariante fueron desarrolladas para tal fin.

Estas técnicas de agrupamiento utilizan unas representaciones denominadas *dendogramas* para representar las afinidades entre actividades como se muestra en la Figura 2.1.22.

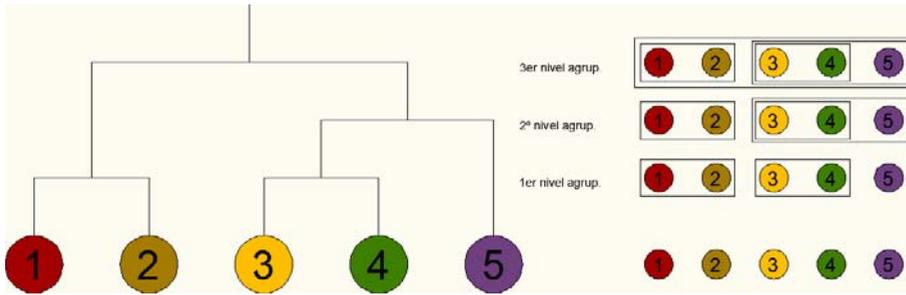


Figura 2.1.22 Dendrograma, adaptado de (Santamarina 1995).

Si al *dendrograma*, que muestra los grupos de actividades homogéneas, se le añade información sobre cómo realizar los cortes para la distribución de las actividades sobre el recinto, el *dendrograma* se transforma en un *árbol de corte*. La información de la forma en la que se realizan los cortes se expresa mediante *operadores de corte* (letras en la Figura 2.1.23).

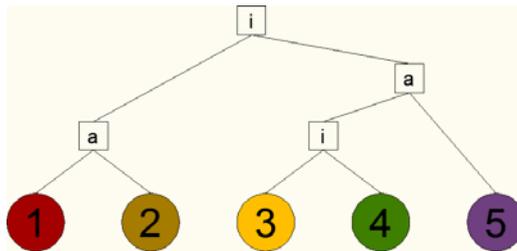


Figura 2.1.23 Representación de un árbol de corte.

Una propiedad exigible a los operadores es la de no producir roturas o disgregaciones de las actividades. Lo habitual es utilizar dos direcciones perpendiculares (cortes verticales y horizontales, respecto a algún sistema de referencia previamente definido) para dividir el dominio de partida, que a priori puede tener cualquier geometría.

| | | ORIENTACION | |
|------------|--|---------------|-------------|
| HORIZONTAL | | ARRIBA (a) | ABAJO (b) |
| VERTICAL | | IZQUIERDA (i) | DERECHA (d) |

Tabla 2.1.1 Operadores de corte.

En la Figura 2.1.24 se muestra el efecto de aplicar los cuatro operadores de corte sobre dos actividades (1,2) de áreas (a_1, a_2) y sobre un recinto de área $A = a_1 + a_2$.

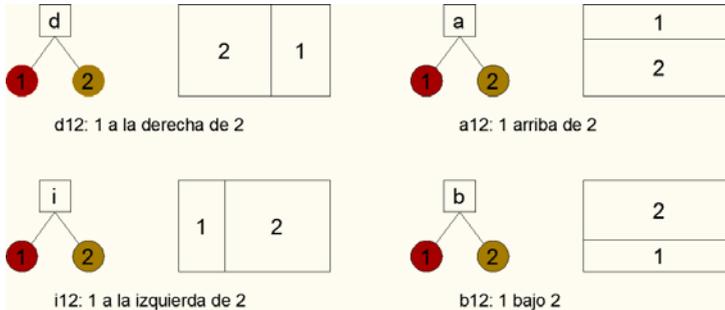


Figura 2.1.24 Aplicación de los operadores de corte sobre dos actividades.

La función de corte también se puede aplicar sobre dos conjuntos de actividades y un recinto de área estrictamente necesaria para contenerlas.

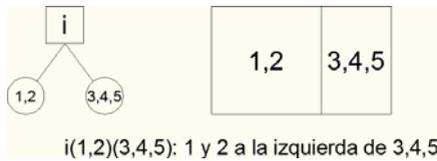


Figura 2.1.25 Aplicación de un operador sobre dos conjuntos de actividades.

Los operadores de corte y las actividades se concatenan en una estructura de árbol binario en lo que se denomina *árbol de corte*, permitiendo la representación esquemática y unívoca de una configuración de la distribución en planta sobre el dominio dado. En la Figura 2.1.26 se muestra un árbol de corte y su distribución biunívoca.

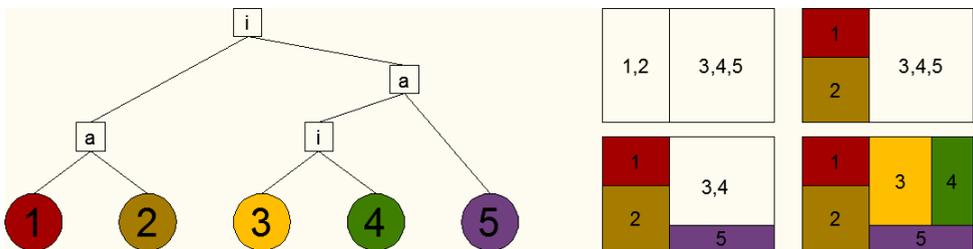


Figura 2.1.26 Representación de una solución mediante árboles de corte.

El tamaño del espacio de configuraciones que puede representar un modelo geométrico basado en árboles de corte puede expresarse como:

$$N = p^{n-1} \prod_{i=0}^{n-2} C_{n-i}^2 = \left(\frac{p}{2}\right)^{n-1} n!(n-1)! \quad (2.21)$$

Donde: p es la cardinalidad del conjunto de operadores.
 n es el número de actividades.
 C_a^b son las combinaciones de a elementos tomados de b en b .

Dentro de los modelos geométricos continuos basados en árboles de corte, se pueden agrupar una serie de técnicas de corte basados en bahías, entre las que se pueden destacar:

Bay Model

En (Meller 1997) se presenta por primera vez un enfoque del problema de distribución en planta mediante un modelo geométrico continuo denominado *bay-model*. Este modelo es muy útil cuando se quiere obtener una configuración de las actividades que facilite un sistema de manutención que pueda ser capaz de mover grandes cargas (puentes grúa) entre distintas naves de una misma planta. La dimensión del recinto es conocida y se adapta a un sistema de naves longitudinales a través del recinto y con sistemas de transporte capaces de intercomunicar las naves (ver Figura 2.1.27). El método tiene dos fases, en la primera se seleccionan las actividades que serán colocadas en cada una de las naves, y en una segunda etapa la configuración de las actividades dentro de cada nave.

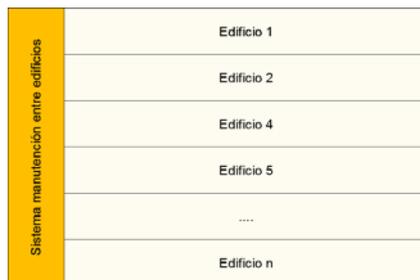


Figura 2.1.27 Modelo Multi-Bay.

Ejemplos de aplicaciones de este tipo son el enfoque MIP de (Montreuil y Ratliff 1989), para el problema de naves simples, o el algoritmo heurístico de (Tate y Smith 1995) para problemas grandes. Hacer notar que este segundo algoritmo es aplicable al problema global si las naves no son necesariamente de igual tamaño y fijas, dando lugar al enfoque conocido como *flex-bay*.

Flex-Bay

Una variante de los *bay-model* es emplear una técnica de *flex-bay* (bahías flexibles), en la que mediante técnicas de agrupamiento se generan conjuntos de actividades afines (un conjunto de j actividades) que se ubican en bahías del ancho estrictamente necesario (b_i) sobre el recinto de dimensiones axh :

$$b_i = \frac{\sum_{j=1}^{n_i} a_j}{h} \tag{2.22}$$

La primera referencia que emplea este modelo geométrico es (Tong 1991), aunque una de las más conocidas es la de (Tate y Smith 1995), en la que aplican un algoritmo genético de optimización con una función de penalización al problema de distribución en planta con restricciones de forma y área desigual. Se muestra en el algoritmo que las soluciones son afectadas por las restricciones de forma de las actividades. En el algoritmo se muestra como una función adaptativa se puede utilizar para encontrar buenas soluciones factibles, utilizando una estrategia de diferentes anchos de banda. En (Norman y Smith 2006) se encuentra otra aplicación de este modelo geométrico.

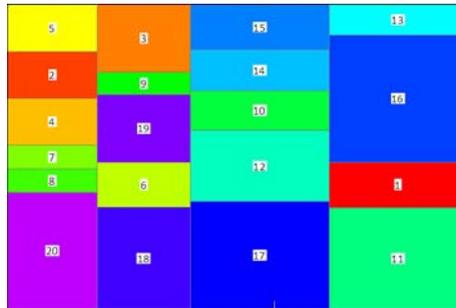


Figura 2.1.28 Representación de una solución de Tate y Smith.

Location matrix

En (Kim y Kim 1998) se presenta un algoritmo en el que se representa la solución mediante una matriz de dos dimensiones que contiene información de la posición relativa de las actividades en el recinto. El número de elementos en la matriz es igual o mayor que el número de actividades (existen posiciones con actividad nula), llamándose a esta matriz *Location Matrix*. El tamaño del recinto donde serán ubicadas las actividades es conocido se emplea un método para dividir el espacio del estilo de los árboles de corte, aunque los autores lo nombran SPM (*Space Partitioning Method*).

Los autores, presentan tres métodos para la descomposición del espacio disponible en el recinto considerando restricciones de forma de las actividades. En el Método A, se establece la dirección de corte principal de la *Location Matrix* (bien sea en filas o columnas) ejecutando entonces el SPM sobre cada fila o columna (ver Figura 2.1.29).

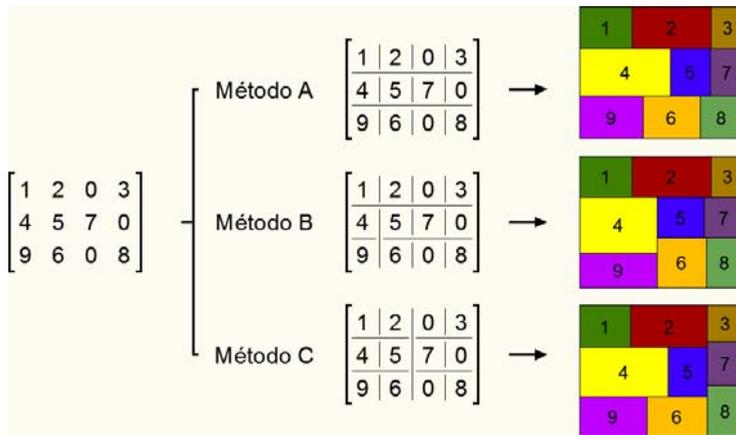
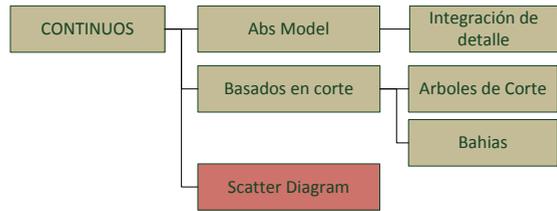


Figura 2.1.29 Métodos A, B y C de (Kim y Kim 1998).

En el método B se establece una dirección de corte (en filas o columnas) y se divide la matriz en dos submatrices, aplicando posteriormente el método A sobre cada submatriz.

En el método C se considera cualquier alternativa para realizar el corte a la hora de ejecutar la descomposición de la matriz, teniendo un conjunto de posibles descomposiciones igual a: $N_{desc} = f + c - 2$, donde f y c son el número de filas y columnas de la matriz, respectivamente. Un modelo muy parecido fue empleado en (Chen, Lin y Chou 2002).



SCATTER DIAGRAM

Otra línea de autores que emplean el espacio de forma continua en 2D son aquellos que emplean una formulación del problema basada en DISCON (*DISpersión-CONcentración*), que originalmente fue propuesta en (Drezner 1980). En esta aproximación, las premisas fundamentales son:

1. Cada una de las actividades se representa por un círculo de radio $r_i = \sqrt{A_i}$.
2. La distancia entre cada par de actividades i y j es la distancia Euclídea:

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

Drezner

Establece una formulación del problema:

$$\min_{(x_i, y_i)} \sum_{1 \leq i < j \leq n} w_{ij} \cdot d_{ij} \quad (1.23)$$

s.t.

$$d_{ij} \geq r_i + r_j \quad \forall 1 \leq i < j \leq n \quad (1.24)$$

En la metodología original, (Drezner 1980) emplea un algoritmo basado en penalizaciones de dos fases.

1. En la primera fase, la de dispersión, todos los círculos se alejan del origen.
2. En la segunda fase, la de concentración, los círculos se concentran y la disposición final es la que marca la solución obtenida.

El problema fundamental de esta metodología es que no se tiene ningún control sobre las dimensiones del recinto donde se ubican las actividades.

A partir de esta formulación establecida por Drezner, se pueden encontrar las aproximaciones de otros dos autores, que han ido evolucionando a lo largo de los últimos años:

Metodología NLT

Años más tarde se propone la metodología NLT en (van Camp, Carter y Vanelli 1991), que supera las deficiencias de la propuesta de Drezner, mediante la inclusión de una serie de restricciones adicionales a las impuestas por aquel y mediante el empleo de formas rectangulares, adoptando la formulación propuesta por Heragu.

La formulación continua propuesta por los autores es la siguiente:

$$\min_{(x_i, y_i), h_i, w_i, h_T, w_T} \sum_{1 \leq i < j \leq n} c_{ij} \cdot d_{ij} \tag{1.25}$$

s.t.

$$\begin{aligned} |x_i - x_j| - \frac{1}{2}|w_i + w_j| &\geq 0 \\ \text{si } |y_i - y_j| - \frac{1}{2}|h_i + h_j| &< 0 \end{aligned} \tag{1.26}$$

$$\begin{aligned} |y_i - y_j| - \frac{1}{2}|h_i + h_j| &\geq 0 \\ \text{si } |x_i - x_j| - \frac{1}{2}|w_i + w_j| &< 0 \end{aligned} \tag{1.27}$$

$$\begin{aligned} \frac{1}{2} \cdot w_T - (x_i + \frac{1}{2} \cdot w_i) &\geq 0 \quad \text{para } i=1, \dots, n \\ \frac{1}{2} \cdot h_T - (y_i + \frac{1}{2} \cdot h_i) &\geq 0 \quad \text{para } i=1, \dots, n \end{aligned} \tag{1.28}$$

$$\begin{aligned} (x_i - \frac{1}{2} \cdot w_i) + \frac{1}{2} \cdot w_T &\geq 0 \quad \text{para } i=1, \dots, n \\ (y_i - \frac{1}{2} \cdot h_i) + \frac{1}{2} \cdot h_T &\geq 0 \quad \text{para } i=1, \dots, n \\ \min(w_i, h_i) - l_i^{\min} &\geq 0 \quad \text{para } i=1, \dots, n \\ l_i^{\max} - \min(w_i, h_i) &\geq 0 \quad \text{para } i=1, \dots, n \\ \min(w_T, h_T) - \ell_T^{\min} &\geq 0 \\ \ell_T^{\max} - \min(w_T, h_T) &\geq 0 \end{aligned} \tag{1.29}$$

Donde: w_i, h_i son las dimensiones de la actividad i-ésima.

$l_i^{\min, \max}$ son la dimensiones máxima y mínima para el menor de los lados de la actividad i-ésima.

w_T, h_T son las dimensiones del recinto.

$\ell_T^{\min, \max}$ son la dimensiones máxima y mínima del recinto.

La metodología NLT emplea esta formulación y una aproximación de tres fases:

1. En la primera fase, intenta distribuir los centros equitativamente en el interior del recinto.

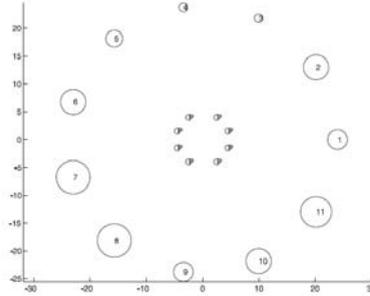


Figura 2.1.30 Fase 1 de la metodología NLT, de (Anjos y Vanelli 2006).

2. En la segunda fase se reduce el solape entre las actividades.
3. En la tercera fase se determina la solución final.

Modelo AR

En (Anjos y Vanelli 2002), los autores presentan un modelo al que denominan AR (*Attractor-Repeller*) basado en los previos de Drezner y van Camp, pues emplea la formulación de DISCON, y tiene en cuenta las restricciones empleadas por NLT.

Los autores plantean un modelo para mejorar el punto obtenido en la fase dos de la metodología NLT, y el problema queda formulado de la siguiente forma:

$$\min_{(x_i, y_i), h_i, w_i, h_T, w_T} \sum_{1 \leq i < j \leq n} c_{ij} \cdot d_{ij} \quad (1.30)$$

s. t.

$$d_{ij} \geq r_i + r_j \quad \forall i, j \quad (1.31)$$

$$\begin{aligned} \frac{1}{2} \cdot w_T &\geq x_i + r_i \quad \text{para } i=1, \dots, n \\ \frac{1}{2} \cdot h_T &\geq y_i + r_i \quad \text{para } i=1, \dots, n \end{aligned} \quad (1.32)$$

$$\begin{aligned} \frac{1}{2} \cdot w_T &\geq r_i - x_i \quad \text{para } i=1, \dots, n \\ \frac{1}{2} \cdot h_T &\geq r_i - y_i \quad \text{para } i=1, \dots, n \\ \ell_T^{\max} &\geq \min(w_T, h_T) \geq \ell_T^{\min} \end{aligned} \quad (1.33)$$

La función objetivo (1.30) y la primera restricción, de no superposición, (1.31) son idénticas a las propuestas en DISCON, el juego de restricciones (1.32) evita la colocación de actividades fuera del recinto de la planta y por último (1.33) controla las dimensiones de la planta. Estas dos últimas restricciones son adaptadas del modelo NLT.

Si se elimina de la formulación el juego de restricciones (1.31), la función objetivo (1.30) se puede considerar como un *Atractor*, pues tendería a soluciones en las que los centros de los círculos (actividades) estuvieran en el mismo punto (ver Figura 2.1.31).

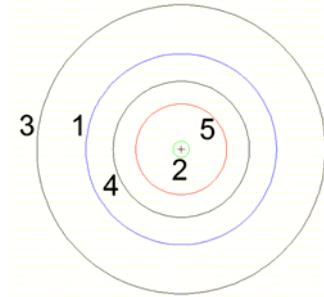


Figura 2.1.31 Efecto atractor de la función objetivo.

Para evitar esto, los autores proponen incluir en la propia función objetivo un término que ejerza de *Repelente*, para conseguir evitar el efecto anteriormente descrito, para ello emplean el concepto de distancia objetivo t_{ij} tal y como se formula en (1.34).

$$t_{ij} = \alpha \cdot (r_i + r_j)^2 \quad (1.34)$$

La distancia entre los centros de los círculos que representan cada una de las n actividades, se determina mediante la distancia Euclídea: $D_{ij} = d_{ij}^2 = (x_i - x_j)^2 + (y_i - y_j)^2$. Por tanto t_{ij} será el valor objetivo para D_{ij} , pues es lo más cerca que pueden estar los círculos sin que se produzca solape entre actividades.

El parámetro α de la ecuación (1.34), proporciona cierta flexibilidad a la hora de permitir el solape entre actividades (si $\alpha < 1$) o no permitirlo (si $\alpha = 1$).

La formulación final propuesta por los autores está compuesta por una función objetivo de dos términos (Atractor y Repelente):

$$\min_{(x_i, y_i), i \in M, h_T, w_T, i, j \in M \cup P} c_{ij} \cdot D_{ij} + \sum_{i, j \in M} f\left(\frac{D_{ij}}{t_{ij}}\right) \quad (1.35)$$

s.t.

$$\begin{aligned} \frac{1}{2} w_T &\geq x_i + r_i \quad \text{y} \quad \frac{1}{2} w_T \geq r_i - x_i \quad \forall i \in M \\ \frac{1}{2} h_T &\geq y_i + r_i \quad \text{y} \quad \frac{1}{2} h_T \geq r_i - y_i \quad \forall i \in M \\ w_T^{\max} &\geq w_T \geq w_T^{\min} \\ h_T^{\max} &\geq h_T \geq h_T^{\min} \end{aligned} \quad (1.36)$$

En la formulación se tiene en cuenta la posibilidad de introducir una diferencia entre las actividades que son de libre disposición (M) y otras cuya disposición debe de ser fija (P).

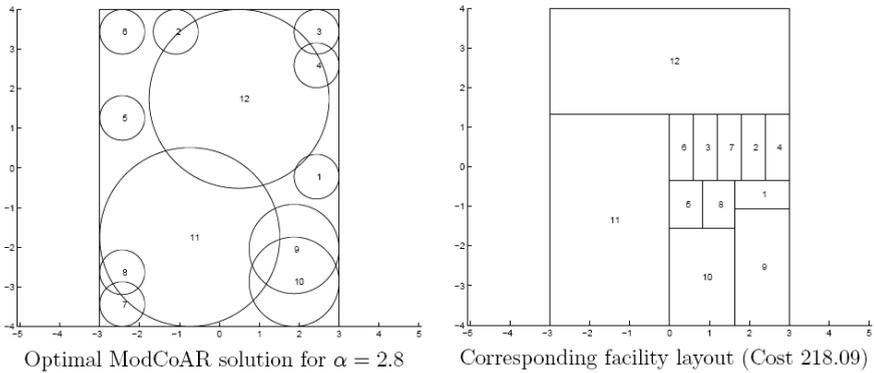


Figura 2.1.32 Transformación de solución en layout de bloques, de (Anjos y Vanelli 2006).

2.1.2.3 Modelos de dos dimensiones y media (MFLP)

Una variante del problema de distribución en planta (FLP) es emplear el espacio en 2 dimensiones y media, es decir, considerar que la actividad se desarrolla en más de una planta de las mismas dimensiones, y la interconexión de todas ellas se realiza mediante el empleo de montacargas. Estos elevadores se consideran un sistema de manutención más, con sus costes de operación, que pueden ser considerados iguales o distintos que el transporte dentro de una misma planta.

La consideración de éste problema como un problema de $2 \frac{1}{2}$ D se debe a que la configuración no puede ser considerada plenamente 3D, ya que la posición de las actividades en el eje Z no es libre, sino que está condicionada a la altura de cada una de las plantas. A este problema, dentro del ámbito de la investigación operativa enfocada a establecimientos industriales se le conoce como MFLP (*Multifloor Facility Layout Problem*)

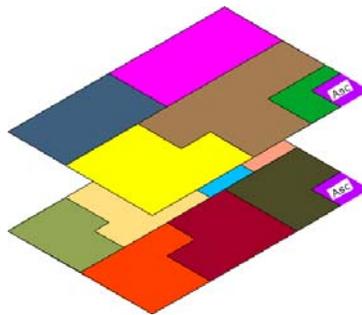


Figura 2.1.33 Distribución de un problema MFLP de dos plantas.

Se puede realizar una clasificación de las aproximaciones al problema en función de la forma en la que se aborda el problema, pudiendo realizarse en una metodología de una única fase, en la que se determine la planta y la posición de cada una de las n actividades o bien una metodología de dos fases:

1. Reducción del flujo entre plantas:

En esta primera fase se distribuyen las actividades en las plantas, de tal forma que se reduzca lo máximo posible el flujo entre plantas.

2. Reducción del flujo en cada planta:

Se busca la solución de ordenación de actividades con menor coste para cada una de las plantas. En esta segunda fase, se puede utilizar un modelo geométrico discreto o continuo, al igual que en el problema 2D (esta segunda fase es un problema FLP).

| 1 FASE | 2 FASES |
|------------------------|----------------------------|
| SPS (1981) | ALDEP (1967) |
| SPACECRAFT (1982) | MSLP (1988) |
| BLOCPAN (1990) | Abdinnour-Helm (1995,2000) |
| MULTIPLE (1994) | STAGES (1997) |
| SABLE (1996) | HGA (2000) |
| MULTIHOPE (1998) | |
| MUSE (1999) | |
| Patsiatzis (2002,2003) | |
| Lee (2005) | |
| Afradeh (2010) | |

Tabla 2.1.2 Clasificación de las metodologías aplicadas MFLP en función de las fases.

La práctica totalidad de autores que han investigado en este problema, han empleado un modelo geométrico discreto, salvo (Matsuzaki, Irohara y Yoshimoto 1999).

La primera mención al problema MFLP se realiza en el *ALDEP (Automated Layout Design Program)* presentado en (Seehof y Evans 1967) que está desarrollado para espacios discretos en dos dimensiones, aunque presenta en el mismo artículo la posibilidad de utilizar el algoritmo en espacios con múltiples plantas.

Esta mención al problema MFLP, contempla la asignación del contorno de espacios libres en el edificio y áreas especiales (escaleras, pasillos, elevadores, otros), y actividades de posición fija.

Formulación de problema

En la bibliografía del problema, se pueden encontrar formulaciones continuas (Patsiatzis y Papageorgiou 2002) y discretas (Bozer, Meller y Erlebacher 1994). La formulación de problema en dos fases es similar a la del FLP. Sin embargo otros autores como Bozer abordan el problema en una sola fase, donde la formulación del problema MFLP es muy similar a la mencionada en el punto anterior, con la salvedad de que hay que añadir en la función objetivo un coste diferenciado para el movimiento de materiales en horizontal y en vertical (se realiza mediante ascensores). En este caso no se emplea el concepto de intensidad relacional (w_{ij}) entre actividades, sino que se considera el coste de movimiento en horizontal (c^H) y en vertical (c^V) y el flujo entre actividades (f_{ij}):

$$\text{Min} \sum_{i=1}^n \sum_{j=1}^n (c_{ij}^H \cdot d_{ij}^H + c_{ij}^V \cdot d_{ij}^V) \cdot f_{ij} \quad (2.37)$$

s.t.

$$d_{ij}^H = \min_a (d_{ia}^H + d_{aj}^H) \quad (2.38)$$

donde a es el número de ascensores, en el caso de ser más de uno, los productos se desplazarán por el que minimice la distancia a recorrer por el producto.

Adicionalmente hay que imponer las restricciones de no superposición y de área completa establecidas en (2.12) y (2.13), así como una cuarta restricción que garantice que no se produce la disgregación de las actividades entre las diferentes plantas del establecimiento.

(Liggett y Mitchell 1981) propusieron SPS (*Space Planning System*), que considera tres costes (fijos, interactivos y de movimiento). Los autores emplean un algoritmo de construcción seguido de una mejora mediante intercambio de actividades. La metodología empleada en la construcción garantiza la regularidad de las actividades, así como la no división de las mismas entre plantas.

SPACECRAFT propuesto por (Johnson 1982) es un algoritmo que, como su nombre indica, está basado en *CRAFT*. En el algoritmo se tiene en cuenta el número y forma de las diferentes plantas, así como el movimiento de materiales entre ellas y los puntos de conexión entre plantas, aunque no considera la inclusión de ascensores.

Se divide cada una de las plantas en módulos rectangulares cada del mismo tamaño (discretización de la planta). Al igual que *CRAFT*, requiere de una solución inicial y el procedimiento de mejora se basa en intercambiar dos o tres actividades contiguas o de igual tamaño. A diferencia de *CRAFT* si que se considera el coste de manutención derivado de movimiento entre plantas.

No implementa ningún control de la agregación de las actividades, por tanto es propenso a la rotura de las mismas.

MSLP es la aproximación realizada por (Kaku, Thomson y Baybars 1988) en la que se emplea una heurística de *k-mediana*, para dividir las actividades en varios grupos de tal forma que se minimice la interacción entre grupos y se maximice la interacción entre los miembros de cada grupo. En la segunda fase, se busca la posición óptima de cada actividad en el grupo mediante intercambio.

BLOCPPLAN es un software propuesto por (Donaghey y Pire 1990) que aborda el problema 2D, así como el *MFLP*. El mismo emplea implícitamente un procedimiento de dos fases, pues pide al usuario que asigne las actividades a cada una de las plantas. Una vez introducidos estos datos, el problema es abordado como suma de dos *FLP*.

MULTIPLE de (Bozer, Meller y Erlebacher 1994) es uno de los algoritmos de referencia en el MFLP. Los autores amplían *CRAFT*, al problema con varias plantas. Con la utilización de las curvas de relleno dan la posibilidad de intercambiar cualquier par de actividades, introducen un control de forma de las actividades y permiten que las áreas de las mismas sean flexibles. Las SFC distribuyen las actividades en todo el recinto (considerado fijo y conocido) y aseguran que las actividades no se dividan, dado que utilizan diferentes curvas para cada piso.

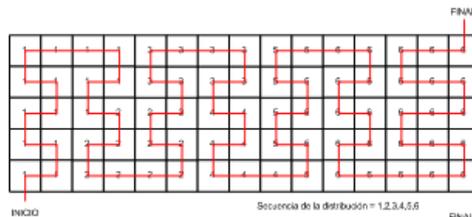


Figura 2.1.34 Uso de SFC para construir la distribución en cada planta (Bozer, Meller y Erlebacher 1994).

Uno de los problemas de *MULTIPLE* es que la heurística empleada es un *steepest descent* con lo cual no es capaz de salir de mínimos locales.

En (Abdinnour-Helm y Hadley 1995) se introduce por primera vez la técnica en dos fases comentada en párrafos anteriores. En la primera fase, los autores determinan las actividades que deben situarse en cada planta mediante una heurística de tipo GRASP, y en la segunda fase, la posición de cada actividad en la planta se determina mediante una heurística del tipo búsqueda tabú. Posteriormente en (Abdinnour-Helm y Hadley 2000), los autores presentan una evolución del algoritmo, en el que se proponen dos aproximaciones, en la primera (GRASP/TS) se mejora la heurística GRASP, para facilitar su mantenimiento y aplicación. En la segunda aproximación (FAF/TS), la primera fase es cubierta mediante un método exacto para la resolución del problema mediante programación lineal y en la segunda fase se emplea la misma heurística basada en búsqueda tabú. En todas las técnicas propuestas los autores emplean un modelo geométrico discreto y SFC para el relleno de las distintas plantas.

SABLE fue propuesto por (Meller y Bozer 1996) como un algoritmo para resolver el MFLP. Utilizan un algoritmo para generar un conjunto más amplio de intercambios y utilizan las SFC en la colocación de actividades. La forma y el área del recinto es conocida. Se genera una solución inicial aleatoria que se va mejorando mediante el intercambio de actividades permitiendo el intercambio de actividades entre plantas.

STAGES de (Meller y Bozer 1997) tiene en cuenta la forma del recinto con dimensión conocida y el área de las actividades. Las mismas serán asignadas a cada planta mediante un procedimiento de dos etapas. En la primera se asignan las actividades que irán ubicadas en cada planta y en la segunda se distribuyen en la planta empleando SFC. La posición de los ascensores es fija en cada problema.

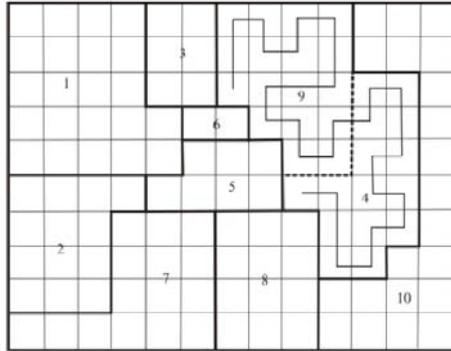


Figura 2.1.35 Colocación de las actividades en la planta mediante SFC.

A este tipo de formulaciones se las conoce como formulación de asignaciones a piso (*Floor Assignment Formulation, FAF*). La diferencia fundamental respecto a SABLE es que se emplea una metodología de dos fases, no dejando que se produzca el intercambio de actividades entre plantas.

MULTI-HOPE, fue propuesto por (Kochhar y Heragu 1998) para resolver el problema de distribución en planta en varios pisos iguales (MFLP). La metodología discretiza cada una de las plantas. Cada actividad se asigna a un conjunto de unidades tal que el área total de esas unidades es igual al área de las actividades. La asignación de las actividades se realiza mediante un listado de asignación y para su colocación en cada una de las plantas se emplea una SFC. La heurística empleada para la optimización es un algoritmo genético.

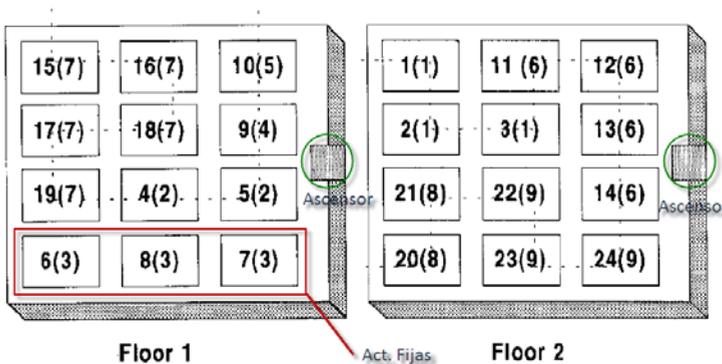


Figura 2.1.36 Distribución en dos pisos (Kochhar y Heragu 1998).

MUSE es la aproximación propuesta por (Matsuzaki, Irohara y Yoshimoto 1999), y está basada en *LOGIC* (Tam y Li 1992), una heurística para la optimización del FLP. *LOGIC* y *MUSE* utilizan expresiones de las distribuciones en planta muy similares, mediante árboles de corte. Los autores introducen el operador “D” en la cadena de codificación de la solución, para denotar el cambio de planta. En la Figura 2.1.37, se muestra la solución con la codificación mostrada en la secuencia de actividades siguiente:

(10–12–L–11–9–R–B–5–6–L–8–7–R–U–D–4–3–B–1–2–U–R–D).

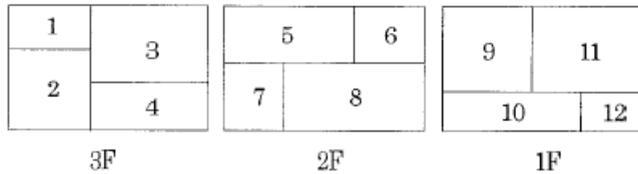


Figura 2.1.37 Distribución de tres plantas empleando el operador “D” (Matsuzaki, Irohara y Yoshimoto 1999).

Los autores se centran en obtener, además de la posición de las actividades en cada planta, el número y posición de los ascensores que optimicen la solución, siendo este enfoque novedoso en el campo del MFLP.

HGA propuesto en (Lin y Chang 2000). En el procedimiento, primero determinan la planta que debe ocupar cada actividad y después se preocupan por la forma (en todos los casos rectangular) y la posición de las mismas. La posición de las actividades en cada planta se determina mediante un algoritmo genético en la segunda etapa del algoritmo.

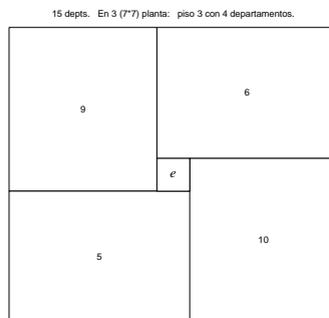


Figura 2.1.38 Distribución en una planta entorno al ascensor (Lin y Chang 2000).

Para la ubicación de las actividades se emplea un listado ordenado y para determinar el intercambio de las actividades se utiliza una regla del estilo ruleta. Los autores discretizan el espacio de cada planta, y establecen una serie de reglas para obligar a que cada actividad tenga una forma siempre rectangular. Esto hace que el aspecto de la solución pueda aparentar emplear un espacio continuo aunque en realidad está discretizado (ver Figura 2.1.38).

Los mismos autores ampliaron el modelo empleado al problema MFLP con la consideración de pasillos, y empleando una metodología de dos fases, la primera mediante un algoritmo *k-mean* y la segunda fase mediante un algoritmo genético en (Chang, Lin y Lin 2006). Las restricciones son las mismas que en el anterior modelo, incluyendo la obligatoriedad de que las actividades sean rectangulares y la no rotura entre otras. Los autores extienden el modelo a edificios de formas no homogéneas mediante la inclusión de zonas no accesibles, tal y como se puede observar en la Figura 2.1.39.

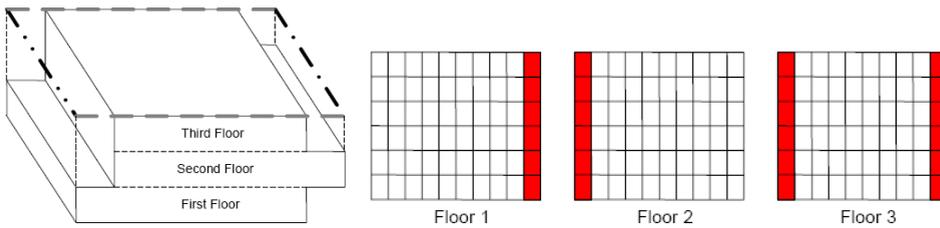


Figura 2.1.39 Áreas de trabajo accesibles en (Chang, Lin y Lin 2006).

Otros autores, como (Patsiatzis y Papageorgiou 2002) y (Patsiatzis y Papageorgiou 2003) plantean la resolución del problema con una formulación de MILP (*Mixed Integer Linear Programming*), fijando un conjunto de restricciones más extenso. En este caso, no se realiza la discretización de cada una de las plantas, sino que se obliga a que todas las actividades tengan forma cuadrada, y que las plantas no se deban ocupar completamente. En el modelo propuesto por los autores, las dimensiones y alturas de las plantas también son variables del problema, algo novedoso en el planteamiento hasta el momento. En la Figura 2.1.40 se puede observar la solución obtenida para uno de los ejemplos de 11 actividades.

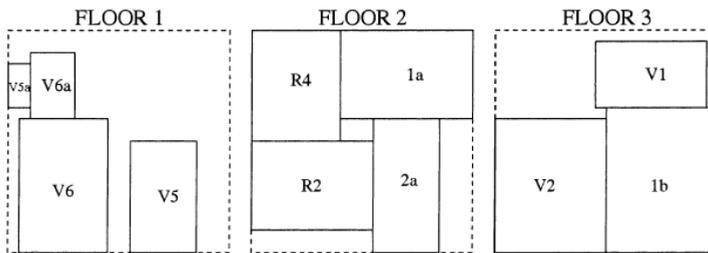


Figura 2.1.40 Solución al ejemplo 3 para el "process plant layout" en (Patsiatzis y Papageorgiou 2002).

En (Lee, Roh y Jeong 2005) se propone un algoritmo genético de mejora para el problema de distribución de planta con varios pisos (*MFLP*). Todas las relaciones entre las actividades, pasillos y ascensores se representan como una grafica de adyacencia. La trayectoria más corta y la distancia entre dos actividades se calculan utilizando el algoritmo de Dijkstra de teoría de grafos. Una vez ubicadas las actividades en cada uno de los pisos, se discretiza cada una de las plantas y se emplean SFC para el relleno.

En la última referencia consultada, (Afrazeh, Keivani y Najafabadi Farahani 2010) se aproximan al problema MFLP con un modelo discreto monocasilla que posteriormente amplían al problema de distribución en planta dinámico (DFLP), en el que se consideran diferentes escenarios de flujo entre las actividades. Utilizan una metodología de una sola fase basada en programación MIP.

2.1.2.4 Modelos de tres dimensiones

El siguiente paso en los modelos geométricos de representación del problema de distribución en planta son los basados en tres dimensiones. En los mismos, los autores consideran un problema en el que todas las actividades tienen una dimensión en planta y además una determinada altura.

Además todas las actividades se pueden posicionar en cualquier posición de Z, siendo la metodología de optimización la que determina la misma. Esta es la diferencia fundamental frente al modelo de dos dimensiones y media (planteado en (Georgiadis et al. 1999)), ya que en el anterior la cota era la de cada una de las plantas preestablecidas.

Esta forma de abordar el problema es relativamente nueva, y está orientado al campo de la ingeniería química, donde se encuentran las aplicaciones más claras, puesto que el flujo entre operaciones es generalmente continuo por medio de tuberías y bombas, que pueden operar a distinta cota.

En (Barbosa-Póvoa, Mateus y Novais 2002) los autores adaptan el modelo basado en MILP (*Mixed Integer Linear Programming*) planteado en (Barbosa-Póvoa, Mateus y Novais 2001) para el problema FLP (2D) al problema de distribución en planta tridimensional. La aplicación de la formulación propuesta está orientada a maquinaria y equipamiento de industrias químicas, aunque propone extenderlo a cualquier tipo de industria o problema.

En el modelo, se definen las unidades de equipamiento (similar a las actividades), que pueden ser regulares o irregulares (puesto que en tal caso pueden ser descompuestas a su vez en módulos que deben ser contiguos entre sí) y pueden estar orientadas en las tres dimensiones cumpliendo únicamente condiciones de conectividad entre ellas.

La función objetivo a minimizar considera el concepto de Coste de conexión entre la salida y la entrada $C_{sal,ent}$ descomponiéndolo a su vez en costes horizontales, de movimiento ascendente y descendente, acompañados cada uno de ellos por las distancias rectilíneas entre puntos de salida y entrada de las distintas unidades.

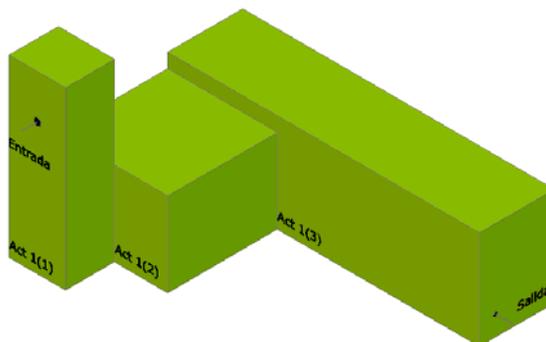


Figura 2.1.41 Entrada y salida de una actividad en 3D.

2.2 MÉTRICA DE LA DISTANCIA

El segundo de los aspectos geométricos a tener en cuenta en el planteamiento del problema de distribución en planta es el relativo a la métrica que se emplee para determinar la distancia entre las actividades del problema a optimizar. La distancia entre las actividades es un parámetro clave, pues contribuye de una manera significativa en la función objetivo a minimizar.

En el problema de distribución en planta se pueden distinguir dos distancias que todo el proceso de definición del mismo:

- *Distancia geométrica*: Este valor viene determinado por las áreas de las actividades, tomándose de forma habitual la distancia Euclídea.
- *Distancia de recorrido*: Es la distancia que van a recorrer los materiales al ir de una actividad a otra. A la hora de determinar esta distancia es muy importante la métrica que se seleccione, pues los valores pueden ser muy distintos.

La selección de una u otra métrica de la distancia de recorrido depende fundamentalmente de los siguientes factores:

1. *Tipo de problema*: Según se esté tratando el diseño de bloques o el diseño de detalle.
2. *Modelo geométrico*: Según se emplee un modelo topológico o geométrico.
3. *Sistema de manutención*: Cada sistema de manutención puede asimilarse a una métrica concreta.

De entre las métricas más empleadas en la bibliografía se pueden destacar las mostradas en la Figura 2.2.1. Cada una de estas es apropiada para una determinada fase del problema o bien para un modelo geométrico concreto, aunque conviene analizarlas en detalle.

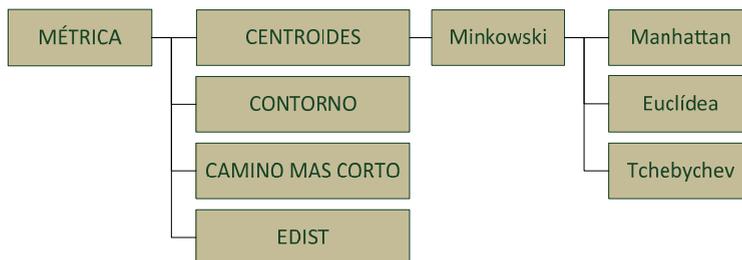


Figura 2.2.1 Clasificación de las métricas de la distancia.

Así, por ejemplo, en la fase de diseño de bloques (o *block layout*), en la que la posición de los puntos de entrada y salida de las actividades no están aun definidos, la distancia entre las mismas se toma respecto al centro de gravedad, siendo para ello valido cualquier métrica Minkowski o la EDIST. En el diseño de detalle, cuando ya se conocen los puntos de entrada y salida de cada una de las actividades se puede emplear una métrica por contorno lateral.

Sin embargo, si se emplea un modelo geométrico topológico, puede resultar adecuado emplear una métrica del tipo camino más corto.

Otros autores como (Ozdemir, Smith y Norman 2003) abogan por emplear una métrica heterogénea, es decir dar la posibilidad de emplear distintos sistemas de manutención en función del flujo entre actividades en función del tipo de sistema de manutención entre actividades.

2.2.1 Distancia entre centroides

En la fase de *block layout* habitualmente se emplea la distancia entre centroides como métrica, debido a que en esta fase del diseño, se suele desconocer el punto de entrada y salida de materiales de la actividad, por tanto, se toma como punto más representativo el centro de gravedad de la actividad.

Todas las distancias entre centroides empleadas se fundamentan en la métrica Minkowski que, se rige por la siguiente expresión:

$$d_{ij}(p) = \left(\sum_{k=1}^{DI} |x_{ik} - x_{jk}|^p \right)^{1/p} \quad (2.39)$$

Donde: DI es el número de dimensiones consideradas.

$p > 0$ es un parámetro que determina la métrica particular utilizada.

De esta formulación se extraen las tres métricas más empleadas en el problema de distribución en planta, en función del tipo de sistema de manutención a emplear en la planta.

Métrica Manhattan

También conocida como métrica rectilínea o rectangular, se obtiene al aplicar en la ecuación (2.39) el parámetro $p=1$. Esta distancia, es frecuentemente utilizada porque es fácil de calcular, de entender, y resulta apropiada para muchos problemas prácticos, donde la manutención se realiza a través de una retícula de pasillos (el transporte de materias se realiza mediante carretillas o vehículos autoguiados).

La distancia rectilínea para el caso de dos dimensiones (x,y) se calcula con la expresión simplificada:

$$d_{ij} = |x_i - x_j| + |y_i - y_j| \quad (2.40)$$

y representa la suma de las distancias horizontal y vertical entre los centros de gravedad de las actividades i y j , tal y como se muestra en la Figura 2.2.2.

Esta métrica es la empleada en la gran mayoría de las referencias bibliográficas del problema de distribución en planta de establecimientos industriales, y será la que se utilice en gran parte del presente trabajo.

Métrica Euclídea

Obtenida de aplicar el parámetro $p=2$ en la ecuación (2.39) es la distancia más corta entre dos puntos, aunque en el caso del problema de distribución en planta no se emplea, pues es una medida irreal, pues la mayor parte de los sistemas de manutención no pueden cruzar por dentro de otras actividades tal y como se puede observar en la Figura 2.2.2.

La distancia Euclídea para el caso de dos dimensiones (x,y) se calcula con la expresión simplificada:

$$d_{ij} = \left((x_i - x_j)^2 + (y_i - y_j)^2 \right)^{1/2} \quad (2.41)$$

Este tipo de métrica sería adecuada en aquellas plantas en las que el flujo de material se realizara mediante cintas transportadoras (Ozdemir, Smith y Norman 2003).

Métrica Tchebychev

Esta métrica se obtiene al aplicar el valor de $p=\infty$ en la ecuación (2.39), que para el caso de dos dimensiones (x,y) y de manera simplificada será:

$$d_{ij} = \max(|x_i - x_j|, |y_i - y_j|) \tag{2.42}$$

La distancia Tchebychev se corresponde con el problema de manutención en una industria de maquinaria pesada que se lleva a cabo mediante puentes grúa con dos motores independientes, uno permitiendo el movimiento en la dirección del eje de las x y el otro en la dirección del eje de las y .

El tiempo necesario para realizar el movimiento desde el centro de la actividad i al centro de la actividad j depende de la mayor de las distancias de los ejes x e y , pues el sistema de manutención empleado comienza el movimiento independiente al mismo tiempo.

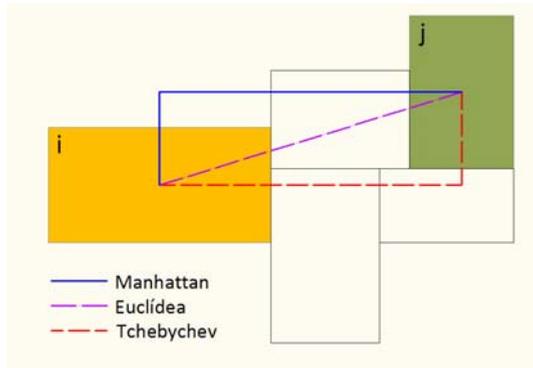


Figura 2.2.2 Topología de las métricas Minkowski.

2.2.2 Distancia por contorno lateral

Otra posibilidad es emplear una métrica que no esté basada en la métrica Minkowski, como es la distancia por contorno lateral. Esta distancia se emplea en problemas de distribución de detalle, en los que se conoce el punto de entrada y salida de cada una de las actividades.

La distancia recorre el camino que deben seguir los materiales desde el punto de salida de una determinada actividad i hasta otra actividad j . En la Figura 2.2.3 se puede observar un ejemplo de distancia por contorno lateral entre dos actividades, que puede ser distinta si el movimiento de materiales es desde i hasta j (en azul) o es de j hasta i (en morado).

La distancia por el contorno es diferente al resto de métricas dado que esta representa la distancia actual del trayecto a lo largo de pasillos que debe seguir una carretilla o vehículo autoguiado. Se pueden encontrar aplicaciones de éste tipo de métrica al problema de distribución en planta en (Norman, Arapoglu y Smith 2001) y (Kim y Goetschalckx 2005).

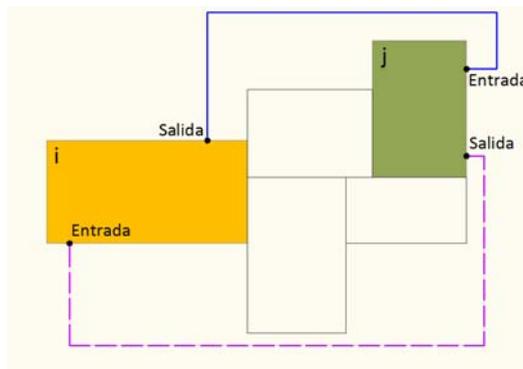


Figura 2.2.3 Distancia por contorno lateral.

El siguiente paso tras obtener la posición de las actividades es la generación de los pasillos y la ubicación de las puertas de cada recinto, (Benson y Foote 1997).

2.2.3 Distancia por camino más corto

Otra métrica empleada en el diseño de detalle es la métrica del camino más corto (*shortest path*). En problemas localización de industrias, ésta métrica es utilizada para determinar la distancia entre dos lugares cuando se emplea un modelo geométrico basado en teoría de grafos. La posición de las actividades se representa mediante un grafo compuesto por nodos y arcos, donde los nodos representan las actividades y un arco entre un par de nodos representa la distancia o tiempo de transporte entre las actividades.

2.2.4 Distancia rectilínea esperada (EDIST)

Otra de las métricas no basadas en Minkowski que se pueden emplear en el problema de distribución en planta en su fase de *block layout* es la distancia rectilínea esperada o EDIST, propuesta en (Bozer y Meller 1997) de la siguiente forma:

Se supone que las actividades *i* y *j* están definidas por las regiones (planares) R_i y R_j respectivamente, con un área total igual a A_i y A_j . Sean las coordenadas de dos puntos de ambas regiones muestreados aleatoriamente $(x_i, y_i) \in R_i$ y $(x_j, y_j) \in R_j$.

Dado que la posición de cada punto es específica para una función de probabilidad uniforme sobre ambas regiones, la distancia rectilínea esperada (EDIST) entre las dos actividades *i* y *j* (d_{ij}) queda fijada mediante la expresión:

$$EDIST_{ij}(d_{ij}) = \int_{x_i \in R_i} \int_{y_i \in R_i} \int_{x_j \in R_j} \int_{y_j \in R_j} \frac{1}{A_i} \cdot \frac{1}{A_j} (|x_i - x_j| + |y_i - y_j|) dy_j \cdot dx_j \cdot dy_i \cdot dx_i \quad (2.43)$$

Si se emplea un modelo geométrico discreto (con *c* casillas) y se expresa el problema en variables de asignación, la distancia EDIST entre ambas actividades se determina mediante la siguiente expresión:

$$EDIST_{ij}(d_{ij}) = \sum_{k=1}^c \sum_{l=1}^c \frac{1}{c_i \cdot c_j} (|x_k - x_l| + |y_k - y_l|) \cdot x_{ik} \cdot x_{jl} \quad (2.44)$$

donde: $x_{ik}=1$ si la posición *k* está ocupada por la actividad *i* y 0 en caso contrario.

$x_{jl}= 1$ si la posición *l* está ocupada por la actividad *j* y 0 en caso contrario.

En la Figura 2.2.4 se puede observar el buen funcionamiento de la métrica EDIST en algunas configuraciones no deseables (diana y sándwich), en las que la métrica Minkowski da valores muy bajos mientras que EDIST las penaliza.

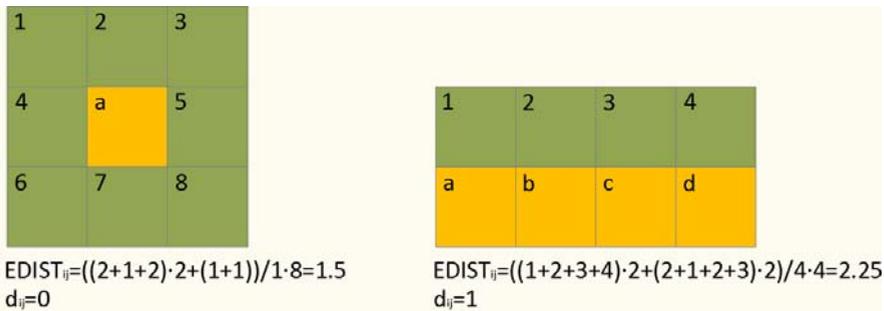


Figura 2.2.4 Ejemplo de aplicación de métrica EDIST.

3 INDICADORES APLICADOS AL PROBLEMA DE DISTRIBUCIÓN EN PLANTA

El problema de distribución en planta tiene un marcado carácter multiobjetivo y son muchos los autores que, tal y como se comentará en el capítulo 5, se han aproximado al problema desde este punto de vista, que ya mostró (Muther 1968) en la confección de la Tabla Relacional de Actividades dentro de la metodología del SLP.

Por tanto, no se debería establecer una metodología para la resolución del problema basada únicamente en el indicador de flujo (como puede ser el coste de transporte de materiales), pues las soluciones obtenidas podrían no representar correctamente la totalidad de los objetivos que se deben cumplir.

En este capítulo se analizarán los objetivos y principios del problema de distribución en planta enunciados por (Apple 1968), (Muther 1968), (Moore 1971) y (Francis y White 1974) y que se consideran la base fundamental en la que se debe apoyar cualquier esfuerzo por obtener una distribución en planta óptima atendiendo a múltiples criterios.

Se realizará un estado del arte de los indicadores que se han empleado en todas las referencias bibliográficas del problema, tanto las que abordan el problema desde un punto de vista monobjetivo como multiobjetivo. Este trabajo, que no se ha abordado hasta el momento, será de gran valor para determinar que indicadores son los más apropiados para considerar cada uno de los principios.

Se depurarán los indicadores asociados a los principios, con la finalidad de eliminar aquellos que sean redundantes y, si es necesario, se propondrán indicadores que puedan resultar útiles para garantizar el correcto cumplimiento de aquellos principios que no tengan ningún indicador asignado.

El objetivo fundamental de este capítulo es encontrar el conjunto de indicadores suficientes e independientes que permitan optimizar las soluciones al problema de distribución en planta de una manera efectiva y cumpliendo con las exigencias marcadas en las metodologías establecidas en la bibliografía.

3.1 OBJETIVOS, PRINCIPIOS E INDICADORES

Tal y como se comentó en capítulos anteriores, la distribución en planta de los procesos industriales debe realizarse atendiendo a una serie de objetivos fundamentales, que han sido establecidos por diferentes autores en sus metodologías para la resolución del problema.

Estos objetivos, que generalmente coinciden entre los distintos autores, se materializan y condensan mediante el cumplimiento de una serie de principios fundamentales, establecidos por (Muther 1955) y deben ser el punto partida a la hora de realizar la optimización del "block layout". Estos principios, muchos de ellos teóricos deben ser cuantificados a través de una serie de indicadores que puedan ser incluidos en la función objetivo que se vaya a utilizar en la optimización.

Para resolver el problema de distribución se pueden formular distintas funciones objetivo, que recojan uno o más indicadores, según sea la aproximación que se pretenda realizar.

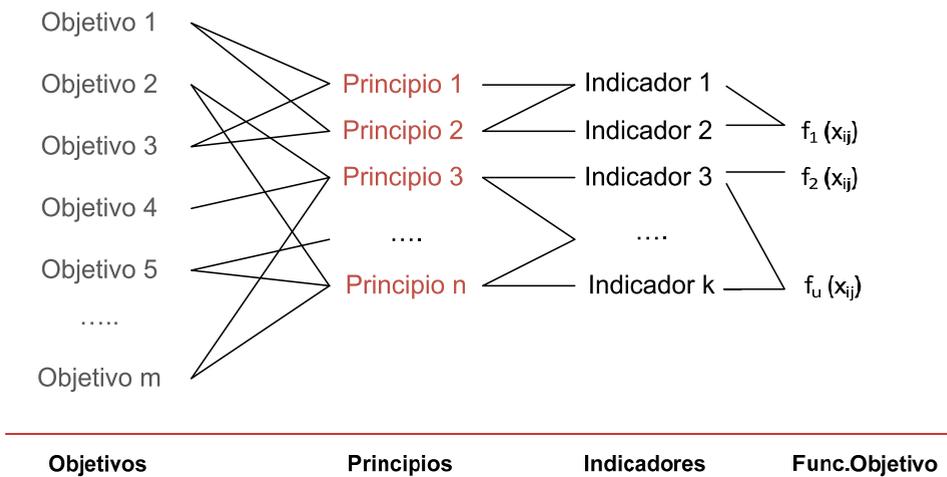
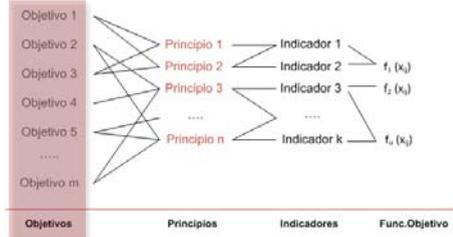


Figura 3.1.1 Objetivos-Principios-Indicadores.

Por tanto, el objeto de este apartado es determinar en primer lugar los **objetivos** de la distribución en planta establecidos en la bibliografía, relacionarlos con los **principios** fundamentales del problema que deben cumplirse en el proceso de optimización y determinar el conjunto de **indicadores** independientes y suficientes que deban considerarse en el conjunto de **funciones objetivo** a utilizar.

3.1.1 Objetivos

3.1.1.1 Muther



Son numerosos los autores que han ofrecido en sus obras recopilaciones de los objetivos perseguidos a la hora de realizar el diseño de la distribución en planta. En una de las citas que definen con una mayor claridad el carácter multiobjetivo del problema de distribución en planta, se remarca:

“...el objetivo perseguido con la distribución en planta es hallar la ordenación de las áreas de trabajo y de la maquinaria, que sea la más económica para el trabajo, al mismo tiempo la más segura y satisfactoria para los empleados...”

(Muther 1955)

Para conseguir una correcta distribución en planta se deben atender, según el autor a los siguientes objetivos:

1. *Reducir los riesgos para la salud y aumentar la seguridad de los operarios.*

Se persigue obtener una distribución que elimine: las herramientas en los pasillos, los pasos peligrosos, la posibilidad de resbalones, los lugares insalubres, la mala ventilación...

2. *Elevar la moral y la satisfacción del trabajador.*

Los trabajadores quieren trabajar en una industria que esté bien planificada, para ello se evita, por ejemplo, el sol de frente, las sombras en el lugar de trabajo.

3. *Incrementar la producción.*

Aún cuando sigan existiendo tiempos ociosos, y retrasos, al disminuirse el número de horas del proceso, se aumenta la productividad.

4. *Disminuir los retrasos en la producción.*

Al equilibrar las operaciones se evita que los materiales, los hombres y las máquinas tengan que esperar. Debe buscarse siempre que "la pieza no toque jamás el suelo".

5. *Ahorrar espacios.*

Al disminuirse las distancias de recorrido y distribuir mejor los pasillos, almacenes, equipamiento y hombres se aprovecha mejor el espacio. Al utilizar varios niveles se obtienen ahorros en las superficies.

6. *Reducir el manejo de materiales.*

Al reagrupar la maquinaria por procesos y operaciones, se acortan las distancias y se mejora la productividad.

7. *Mayor uso de la maquinaria, la mano de obra y los servicios.*

Si la mano de obra es costosa debe emplearse mejor su tiempo, si la mano de obra es barata pero la maquinaria y los materiales son costosos se debe buscar el mejor aprovechamiento de éstos.

8. *Reducir el material en proceso y el tiempo de fabricación.*

Al aplicar una secuencia lógica y disminuir las distancias, el material permanece menos tiempo en el proceso, disminuyendo las demoras. Al disminuir las distancias, demoras y almacenamientos innecesarios el producto estará listo para la venta más rápidamente. Se deben eliminar, en la medida de lo posible, los almacenamientos intermedios, para obligar al material a fluir de manera continua.

9. *Reducir el trabajo administrativo y el trabajo indirecto en general.*

Al seguir el proceso un flujo bien determinado, se puede reducir la preparación de órdenes y de programas. Al disminuirse las operaciones y los transportes inútiles, se disminuye el trabajo indirecto.

10. *Lograr una supervisión fácil.*

Se aumenta el área de visión, de forma que los supervisores se deben mover menos para realizar su trabajo, determinando fácilmente en qué punto del proceso se produce un retraso.

11. *Disminuir la congestión y confusión.*

Se deben evitar los retrasos y los cruces de procesos, para eliminar así la confusión, pues se tiene el espacio preciso y adecuado para cada operación.

12. *Disminuir el riesgo para el material o su calidad.*

Al separar las operaciones se reducen las influencias nocivas de unas a otras. Por ejemplo, se pueden aislar, las operaciones delicadas de las que pueden causar daños.

13. *Aumentar la facilidad de ajuste a los cambios de condiciones.*

Al prever las ampliaciones, los aumentos de demanda o reducciones del mercado se eliminan los inconvenientes de las expansiones o disminuciones de la planta.

14. Otras ventajas diversas;

Facilitar las labores de mantenimiento, las condiciones sanitarias y el control de los costes. Al reunir procesos similares, se facilita la contabilidad de costes. Al reunir los equipos similares, y separarlos de otros que los pudieran dañar, se aumenta la vida útil de la maquinaria, pues se facilitan las reparaciones y el control de la misma.

Muther condensa los 14 objetivos enunciados anteriormente en seis objetivos básicos que son la fuente de los principios básicos enunciados por el autor:

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 de ordenación para facilitar cualquier reajuste.*

3.1.1.2 Otros autores

Posteriormente, Moore define la distribución en planta óptima como:

“...aquella que proporciona la máxima satisfacción a todas las partes implicadas en el proceso de implantación: los empleados y los directivos, así como los accionistas...”

(Moore 1962)

y propone, como objetivos a tener en cuenta en el proceso de generación de la misma los siguientes:

1. *Simplificar al máximo el proceso productivo.*
2. *Minimizar los costes de manejo de materiales.*
3. *Disminuir al máximo el trabajo en curso.*
4. *Utilizar el espacio de la manera más efectiva que sea posible.*
5. *Promover la seguridad en el trabajo, aumentando la satisfacción del operario.*
6. *Evitar inversiones de capital innecesarias.*
7. *Estimular la eficiencia de la mano de obra.*

También (Apple 1968) establece, desde su punto de vista, los ocho objetivos fundamentales que debe cumplir toda distribución en planta en su planeamiento:

1. *Facilitar el proceso de fabricación.*
2. *Minimizar el transporte de material.*
3. *Mantener la flexibilidad.*
4. *Disminuir el trabajo en curso (Work in Process).*
5. *Contener la inversión en equipamiento.*
6. *Maximizar el rendimiento del espacio de la planta.*
7. *Promover el uso efectivo de la mano de obra.*
8. *Garantizar la seguridad y el confort de los operarios.*

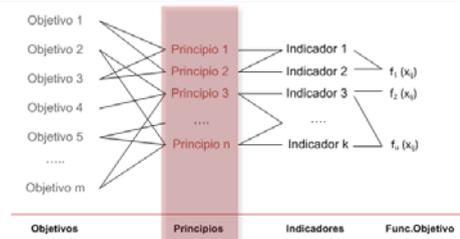
Tal y como cita Contero, (Dowlatshahi 1994), basándose en lo establecido por Francis y White, enuncia 11 objetivos principales a la hora de generar una distribución en planta:

1. *Minimizar los costes de operación del equipamiento y en la planta.*
2. *Aumentar el uso efectivo y económico del espacio.*
3. *Proporcionar a los empleados comodidad, seguridad y confort.*
4. *Mantener la flexibilidad de la organización y operación.*
5. *Minimizar el coste de mantenimiento del material, y el tiempo y frecuencia de las manipulaciones.*
6. *Minimizar el número de tipos de equipos de mantenimiento del material.*
7. *Facilitar el proceso de fabricación y el flujo de operaciones.*
8. *Facilitar la estructura organizativa y la toma de decisiones por la dirección.*
9. *Minimizar los riesgos y las molestias al público.*
10. *Mantener una construcción segura y eficiente.*
11. *Cumplir con la normativa legal de salubridad, emergencia y ambiental.*

En todas las aproximaciones a la determinación de los objetivos básicos de toda distribución en planta se puede observar que existen muchos puntos en común y que pueden cambiar el número y agrupación de las características, pero la esencia de los objetivos es común a todos los autores.

3.1.2 Principios

Muther, una vez enunciados los 14 objetivos a tener en cuenta en el proceso de generación de la mejor distribución en planta posible, y reducidos estos a los 6 objetivos básicos, los expresa en forma de principios, constituyéndose éstos en la base de la metodología que posteriormente formularía como el SLP:



a) Principio de integración de conjunto.

“La mejor solución será aquella que integre a los operarios, materiales, maquinaria y cualquier otro factor de forma que el compromiso entre todos ellos resulte mayor”

La distribución en planta debe obtenerse como resultado de la integración de todos los medios de producción, tanto directos como auxiliares en una unidad operativa, convirtiendo la planta en una única máquina.

b) Principio de la mínima distancia recorrida.

“En igualdad de condiciones, la mejor solución será aquella que permita al material desplazarse la mínima distancia posible”

En cualquier proceso industrial, el material (o la maquinaria) se debe desplazar por la planta, puesto que es prácticamente imposible que el proceso sea completamente lineal. Asumiendo esta premisa, lo más aconsejable será que el recorrido sea mínimo, puesto que no añade ningún valor al producto.

c) Principio de la circulación.

“En igualdad de condiciones, la mejor solución será aquella 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”

Este principio es complementario con el de la mínima distancia recorrida, se estima mejor la solución que haga que el material (o la maquinaria) tenga que transitar lo menos posible por los pasillos.

El concepto de circulación se centra en la idea de un constante movimiento hacia la terminación del producto, con un mínimo de interrupciones, interferencias o congestiones, más bien que en una idea de dirección.

d) Principio del espacio cúbico.

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

Una buena distribución en planta debería de aprovechar la tercera dimensión, puesto que los medios de producción pueden moverse en cualquiera de las tres dimensiones. Hay que prever, por lo tanto, la posibilidad de utilizar varias alturas a la hora de realizar la distribución.

e) Principio de satisfacción y seguridad.

“En igualdad de condiciones, la mejor solución será aquella que haga el trabajo más satisfactorio y seguro para los operarios, los materiales y la maquinaria”

El operario desarrollará su trabajo de manera más efectiva si se encuentra satisfecho y seguro, así que todo lo que ayude a fomentar estas dos condiciones, redundará en la efectividad de la distribución.

f) Principio de flexibilidad.

“En igualdad de condiciones, será más efectiva la solución que pueda ser ajustada o reordenada con menos costos o inconvenientes”

Desde los primeros trabajos en el ámbito de la optimización multiobjetivo del problema de distribución en planta, este fue uno de los factores que se tuvieron en cuenta, puesto que debido a los cambios tecnológicos y a los cambios en la producción, las plantas industriales deben ser capaces de adaptarse a un nuevo entorno con rapidez y a un coste mínimo.

“...si la flexibilidad es definida como la facilidad por la cual las actividades pueden ser situadas y resituadas, podemos medirla en términos de un índice de cercanía entre las actividades...”

(Malakooti y D'Souza 1987)

“La flexibilidad es la capacidad de cambiar o adaptarse con poca penalización en el tiempo, esfuerzo, coste o rendimiento”

(Upton 1994)

Asimismo el autor reseña el carácter multidimensional de la flexibilidad, pues debe ser entendida según distintos puntos de vista: Determinación de itinerarios, Productos, Composición, Funcional...

Posteriormente, otros autores también han hecho hincapié en la importancia de la flexibilidad:

“La flexibilidad implica dos aspectos: el primero relativo a la capacidad de realizar una variedad de tareas en diferentes condiciones y una segunda relativa a la capacidad de ampliar la planta”

(Yang y Hung 2007)

Otro aspecto importante, que algunos autores han introducido en los últimos años es el de la flexibilidad de la configuración (o Facilities Layout Flexibility, FLF):

“la flexibilidad de la configuración es la capacidad de ésta para soportar efectivamente las sucesivas variaciones que surjan en los cambios de requerimientos de los clientes y de modificaciones internas en las empresas en términos de costes y tiempo.”

(Raman, Nagalingam y Lin 2009)

Sin embargo, tal y como se verá en apartados posteriores, la flexibilidad de la configuración no es una característica sencilla de medir, y más desde el punto de vista del layout de bloques, en el que únicamente se reserva un área de la planta para instalar las actividades. Por tanto resulta interesante definir un objetivo de flexibilidad a menor escala como es la **flexibilidad geométrica** de una actividad.

La flexibilidad geométrica del área reservada a una determinada actividad es la capacidad del mismo para admitir cambios de implantación de la actividad sobre él. Es decir, se dice que un área es flexible cuando admite diferentes configuraciones internas de la actividad. De esta forma, las actividades con un área reservada más compacta serán más flexibles que las que tengan un área más dispersa, y las áreas con forma cuadrada tendrán una mayor capacidad de albergar cambios en la configuración interna de la actividad que las excesivamente alargadas.

Se pueden asignar a cada uno de los principios básicos enunciados por Muther los objetivos que el mismo autor propuso inicialmente, para tener una referencia de la importancia de cada uno de los principios básicos.

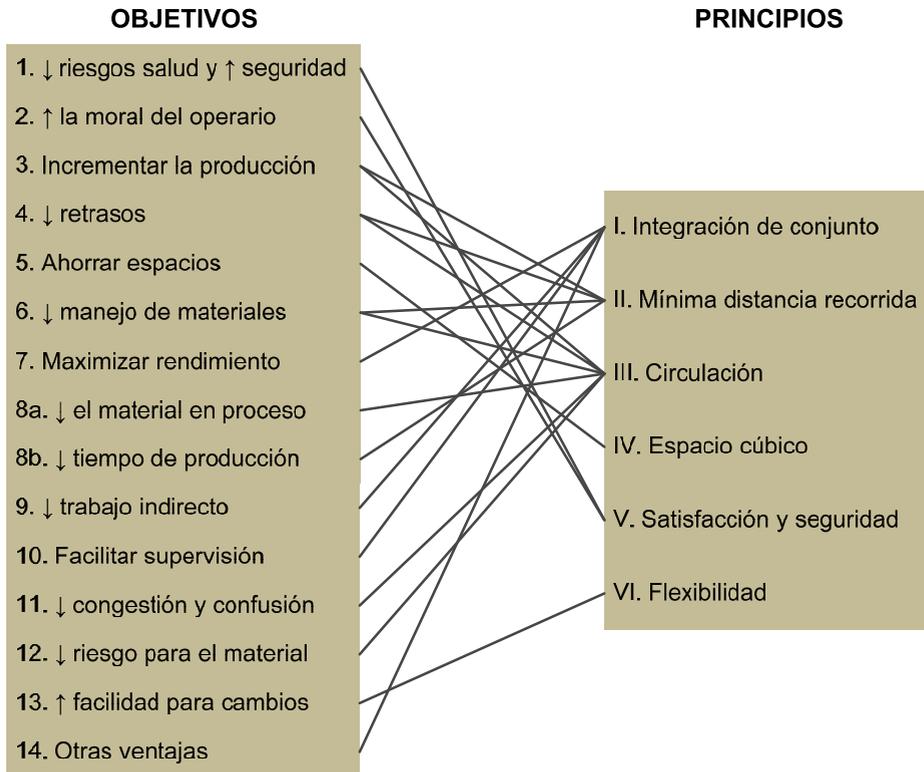
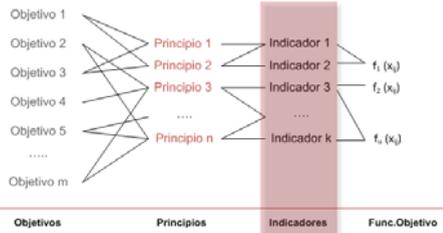


Figura 3.1.2 Relación entre Objetivos y Principios enunciados en (Muther 1955).

Tal y como se puede observar en el esquema, el principio de circulación es el que aglutina un mayor número de principios (6), seguido de la integración de conjunto y la mínima distancia recorrida (4 cada uno). Por ello resultará fundamental encontrar indicadores que permitan cuantificarlos y realizar una correcta optimización de la distribución en planta.

Una vez conocidos los objetivos básicos de una correcta distribución en planta, y los principios que se deben cumplir a la hora de realizar la concepción de la misma, resta conocer los indicadores que se puedan emplear numéricamente en el proceso de optimización.

3.2 INDICADORES EMPLEADOS EN EL PROBLEMA DE DISTRIBUCIÓN EN PLANTA



Una vez conocidos los principios básicos que deben regir el proceso de optimización de la

distribución en planta, se buscan los indicadores que se han empleado en las referencias bibliográficas que han abordado el problema de distribución en planta. Posteriormente, se buscarán las relaciones entre indicadores y principios básicos.

Los indicadores que han aplicado los diferentes autores al problema se pueden clasificar en dos grandes grupos, aquellos que son cualitativos, es decir que no son cuantificables medida física o geométrica, sino que deben recurrir a calificaciones otorgadas por un evaluador externo. Por otra parte se consideran los indicadores cuantitativos, que pueden ser obtenidos por la medida de alguna característica física o geométrica del layout de bloques. Estos últimos son los más interesantes, pues las medidas se pueden realizar automáticamente sobre la solución, siendo mucho más sencillo realizar la automatización del proceso de optimización del problema.

En la siguiente figura se muestra una clasificación de los indicadores que se describirán con detalle en el presente capítulo.



Figura 3.2.1 Clasificación de los indicadores aplicados al FLP.

3.2.1 Indicadores Cualitativos

Un gran número de autores han empleado indicadores cualitativos a la hora de incluir diferentes objetivos básicos en sus investigaciones, todos ellos requieren de un panel de expertos que asigne a cada par de actividades un orden de preferencia así como una relación directa entre el valor cualitativo y uno cuantitativo para realizar la agregación.

3.2.1.1 Índice de cercanía (Closeness Rating)

El indicador cualitativo por excelencia en las referencias existentes al problema es el índice de cercanía o *Closeness Rating* (CR_{ij} o r_{ij}). Éste se obtiene de la Tabla Relacional de Actividades (Francis y White 1974), que es un cuadro organizado en diagonal, en el que se plasman las relaciones de cada actividad con las demás. En ella, un experto (o panel de expertos), evalúa la necesidad de proximidad entre las diferentes actividades bajo diferentes puntos de vista.

La relación entre actividades se valora entre **A** (absolutamente importante) y **U** (no importante), y generalmente se emplea la **X** para relaciones indeseables. Estos valores son transformados en numéricos empleando diferentes escalas:

| | A | E | I | O | U | X |
|--------------------------|----|----|---|---|---|-------|
| (Moore 1971) | 6 | 5 | 4 | 3 | 2 | 1 |
| (Fortenberry y Cox 1985) | 5 | 4 | 3 | 2 | 1 | -1 |
| (Urban 1987) | 4 | 3 | 2 | 1 | 0 | -1 |
| (Chen y Sha 1999) | 64 | 16 | 4 | 1 | 0 | -1024 |
| (Ye y Zhou 2007) | 5 | 4 | 3 | 2 | 1 | 0 |

Tabla 3.2.1 Valores de transformación para CR_{ij} .

Las referencias en las que se emplea el índice de cercanía (CR), con datos obtenidos a través de la TRA son las siguientes:

| | | |
|-----------------------------------|-----------------------------|--------------------------|
| (Rosenblatt 1979) | (Dutta y Sahu 1982) | (Fortenberry y Cox 1985) |
| (Rosenblatt y Sinuany-Stern 1986) | (Waghodekar y Sahu 1986) | (Urban 1987) |
| (Urban 1989) | (Khare, Khare y Neema 1988) | (Houshyar 1991) |
| (Harmonosky y Totho 1992) | (Suresh y Sahu 1993) | (Badiru y Arif 1996) |
| (Chen y Sha 1999) | (Sha y Chen 2001) | (Chen y Sha 2005) |
| (Sahin y Türkbey 2009) | (Singh y Singh 2009) | |

Algunos autores también emplean un índice de cercanía, en este caso obtenido mediante la evaluación de diversos subcriterios (que se pueden corresponder con alguno de los indicadores que se exponen en puntos posteriores):

- (Sarin et al. 1992), emplean una serie de criterios que constituyen un índice de cercanía “agregado”, los valores de cada criterio se normalizan mediante el empleo de una serie de funciones de transformación, tal y como se comentó en el capítulo anterior.

- (Shang 1993), obtiene una matriz normalizada de valores para el índice de cercanía mediante una técnica AHP en la que integra toda una serie de criterios que influyen a la hora de determinar el valor de la matriz. Estos criterios son: Seguridad, Ruidos, Flexibilidad, Estética, Temperatura y trabajo en curso. Todos ellos son evaluados mediante un panel de expertos, que determinan la importancia de cada uno de ellos entre cada par de actividades.

Otros autores, como (Sangwan y Kodali 2006) y (Raoot y Rakshit 1993), emplean técnicas de lógica borrosa para determinar el valor del índice de cercanía entre las actividades.

Por último (Aiello, Enea y Galante 2006) establecen el indicador de una forma inversa, no en términos de cercanía sino de alejamiento, además lo formulan de una forma cuantitativa. Es un indicador muy similar a los de cercanía:

$$\text{separación} = \sum_{i=1}^n \sum_{j=1}^n s_{ij} \cdot d_{ij} \quad (3.1)$$

Donde: s_{ij} es la necesidad de separación entre las actividades i y j .

d_{ij} es la distancia entre las actividades i y j .

3.2.1.2 Flexibilidad

Otro de los indicadores empleados en el problema es la flexibilidad, que tal y como se ha comentado con anterioridad coincide con uno de los principios básicos establecidos por Muther.

Algunos autores han evaluado este indicador de forma **cuantitativa**, en (Malakooti 1987) y (Raman, Nagalingam y Lin 2009) se comentan las diferentes aproximaciones que se han hecho a la medida de la flexibilidad en las plantas industriales:

- Generando una serie de matrices de flujo diferentes para representar las variaciones en la demanda de diferentes productos. La configuración con el menor MHC para los diferentes escenarios es el que tiene una mejor flexibilidad. Autores como por (Webster y Tyberghein 1979), (Shore y Tompkins 1980) y (Yang y Peters 1998) siguieron este camino.
- (Rosenblatt y Lee 1987) exponen que la configuración más flexible es aquella en la que el MHC permanezca dentro de un rango pese a las variaciones de flujo.

En ambos casos, el MHC es el factor fundamental para tomar la decisión de que configuración es la más flexible, sin embargo en la realidad hay otros factores que se deben tener en cuenta para calcular la flexibilidad de la configuración. Otras aproximaciones para medir la flexibilidad son:

- En términos de la cantidad de elementos para unir las unidades productivas: (Affentakis 1985), (Chaterjee et al. 1984).
- Combinado varios factores como son: Flexibilidad para la expansión, Flexibilidad en el volumen de producción y Flexibilidad en las rutas, todos ellos con medidas muy difusas. (Raman, Nagalingam y Lin 2009) los tratan con lógica borrosa para determinar un valor del FLF, que está normalizado entre 0-1 y que tratan de maximizar.



Figura 3.2.2 Factores para calcular FLF (Raman, Nagalingam y Lin 2009).

Otro grupo de autores emplean valores **cuantitativos** para este indicador, así el primer autor que emplea la flexibilidad en el estudio multiobjetivo del problema es Malakooti en (Malakooti y D'Souza 1987), (Malakooti 1987) y (Malakooti 1989). Siempre en los siguientes términos: “...el efecto que tiene la cercanía de dos actividades en la flexibilidad de la solución...”. Por tanto la medida de esta flexibilidad es completamente subjetiva y se cuantifica de la misma forma que el índice de cercanía, mediante una escala de letras que marcan la necesidad de proximidad de las actividades para obtener una solución más flexible.

Otros autores, consideran la flexibilidad como uno de los aspectos a tener en cuenta en la evaluación de un índice de cercanía obtenido mediante AHP, de entre ellos destacan: (Shang 1993) , (Yang y Kuo 2003) y (Yang y Hung 2007).

3.2.1.3 Adyacencia

Un indicador muy similar al índice de cercanía es la adyacencia, definida como la necesidad de que dos actividades se encuentren próximas. Algunos autores como (Meller y Gau 1996) y (Tuzkaya, Ertay y Ruan 2005) hacen referencia a la adyacencia en términos de proximidad cuanto mayor sea el flujo y de penalidad si las actividades no son adyacentes, respectivamente. En (Aiello, Enea y Galante 2006) se propone una formulación matemática para el indicador de adyacencia de la siguiente forma:

$$\text{adyacencia} = \sum_{i=1}^n \sum_{j=1}^n r_{ij} \cdot l_{ij} \quad (3.2)$$

Donde: r_{ij} es el índice de cercanía entre actividades.

l_{ij} es el perímetro de contacto entre las actividades i y j .

En (Ye y Zhou 2007) se hace una formulación similar:

$$\text{adyacencia} = \sum_{i=1}^n \sum_{j=1}^n r_{ij} \cdot b_{ij} \quad (3.3)$$

Donde: b_{ij} es el factor de adyacencia, y se obtiene a partir de la distancia entre centroides, mediante la Tabla 3.2.2.

| d_{ij} (m) | b_{ij} |
|--|----------|
| $0 < d_{ij} < d_{\max}/6$ | 1 |
| $d_{\max}/6 < d_{ij} < d_{\max}/3$ | 0.8 |
| $d_{\max}/3 < d_{ij} < d_{\max}/2$ | 0.6 |
| $d_{\max}/2 < d_{ij} < 2 \cdot d_{\max}/3$ | 0.4 |
| $2 \cdot d_{\max}/3 < d_{ij} < 5 \cdot d_{\max}/6$ | 0.2 |
| $5 \cdot d_{\max}/6 < d_{ij} < d_{\max}$ | 0 |

Tabla 3.2.2 Factor de adyacencia

3.2.1.4 Movimientos peligrosos

El primer autor que hace referencia al indicador de movimientos peligrosos (*Hazardous Movement*) es (Waghodekar y Sahu 1986) en el que se tienen en cuenta a la hora de elaborar un indicador de cercanía. Posteriormente (Chen y Sha 2005) también lo utilizan como uno de los objetivos a minimizar (en términos de reducir las distancias entre actividades en las que se manejen materiales peligrosos). La última referencia en la que se emplea este indicador es (Singh y Singh 2009), en la misma línea de los autores anteriores.

Este indicador no se encuentra formulado en ninguna de las referencias, sino que los autores emplean una tabla de valores que cita el problema tipo de (Waghodekar y Sahu 1986) y no le dan un sentido físico al mismo, no siendo por tanto un indicador propiamente dicho.

3.2.2 Indicadores Cuantitativos

A pesar de que los indicadores cualitativos aportan una información importante en el proceso de generación de soluciones eficientes en el problema de distribución en planta, hay muchas otras características que son medibles y que pueden aportar una información muy valiosa en el proceso de toma de decisiones.

Los indicadores cuantitativos aportan medidas precisas y reales de la bondad de una solución y permiten, mediante heurísticas conseguir soluciones que mejoren a las actuales. A continuación se realiza una búsqueda de los indicadores cuantitativos que se pueden encontrar en la bibliografía, en que caso se emplea cada uno de ellos y cómo se pueden utilizar en esta investigación.

3.2.2.1 Indicadores de Flujo

Una primera medida cuantitativa de la calidad de una solución es el flujo que se produce en la misma. El flujo que habitualmente se emplea, por ser el que tiene una mayor repercusión en los costes, es el de materiales, aunque algunos autores también reseñan la importancia del flujo de personal o de maquinaria. Otra forma de medir el flujo es mediante el tiempo de transporte, que incluye los medios de manutención.

Todos los indicadores cuantitativos de flujo proporcionan un valor correspondiente a toda la configuración. A continuación se describen los más significativos y se propone un nuevo indicador, el indicador de circulación.

3.2.2.1.1 Coste de transporte de materiales (MHC)

El objetivo principal del problema de distribución en planta (igual que en el QAP) es la reducción del coste de transporte de materiales (*Material Handling Cost*). No es propiamente un indicador, aunque ciertamente da la medida de la calidad de la solución en términos de coste, puesto que como resaltan (Tompkins et al. 1996) el coste de transporte interior de materiales puede suponer entre el 20-50% de los costes de fabricación. Absolutamente todas las referencias que abordan el problema desde una dimensión multiobjetivo tienen en el MHC o en el flujo su objetivo fundamental.

3.2.2.1.2 Tiempo de movimiento de los materiales (MMT)

Otro de los indicadores de flujo empleados en la bibliografía fue introducido por (Malakooti y D'Souza 1987) y (Malakooti 1989), y es el tiempo de movimiento de los materiales. Apuntan los autores que es un indicador de la eficiencia de las operaciones, puesto que cuanto más rápido se mueva el material, mayor será la productividad de la planta. El tiempo de movimiento de materiales se calcula como el coste de transporte de materiales, salvo que se emplea el tiempo en lugar del coste por unidad de distancia viajada entre actividades.

Este indicador depende, en buena medida del sistema de manutención empleado, los datos se deben recopilar en una tabla (desde/hacia) en el que para cada par de actividades se proporcione el tiempo por unidad de distancia.

Posteriormente es empleado también por (Chen y Sha 2005) y (Singh y Singh 2009).

3.2.2.1.3 *Indicadores de flujo de Lin y Sharp*

En (Lin y Sharp 1999a) se realiza una aportación singular al ámbito de los indicadores aplicados al problema de distribución en planta, pues presenta 18 indicadores (agrupados en 3 categorías) para optimizar el problema. Algunos de ellos son cualitativos, aunque los pertenecientes al grupo Flujo son todos cuantitativos.

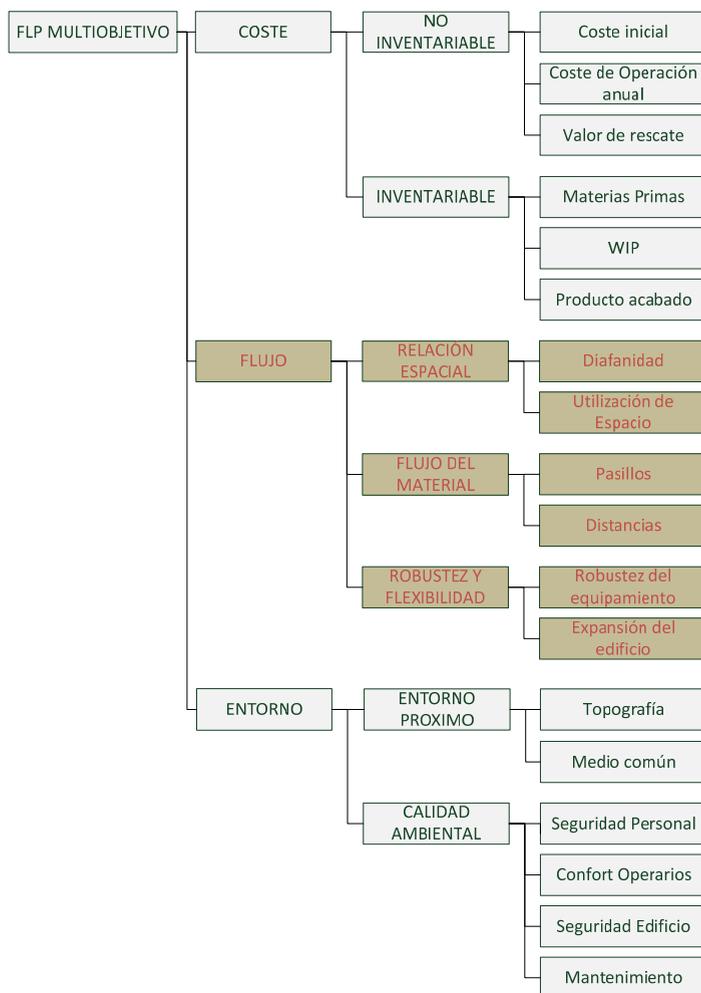


Figura 3.2.3 Indicadores de (Lin y Sharp 1999a).

De todos los indicadores, para la presente investigación son de mayor interés todos aquellos que están agrupados en el Flujo (aunque algunos de ellos no tengan una clara influencia en el flujo como tal y no se realice la integración de todos ellos para poder realizar la optimización).

Diafanidad

Se describe la diafanidad (Lin y Sharp 1999a) como la extensión de la planta que está libre de elementos constructivos que puedan afectar a la efectividad de la asignación espacial en una determinada configuración. Hay tres elementos constructivos que afectan a este indicador: tabiques, pilares y escaleras (o ascensores). Una de las fuentes del desaprovechamiento espacial en los edificios industriales, se producen habitualmente por un incorrecto posicionamiento de estos elementos constructivos.

- Los tabiques influyen en las posibles ubicaciones de las actividades, pues fraccionan la planta.
- Los pilares afectan al posicionamiento de la maquinaria, así como a los medios de manutención. Los autores llaman a los espacios en los que hay algunos pilares interiores, Espacio Semi-Abierto (ESA) y a los espacios sin columnas interiores Espacio Abierto (EA).
- Las escaleras (o ascensores) afectarán al sistema de manutención, a la distancia recorrida por los productos o por los trabajadores. Así en un edificio de oficinas (o de viviendas) las escaleras deben estar situadas en el centro (para reducir así los recorridos de los trabajadores) y sin embargo en un edificio de producción, es más adecuado que esté en una esquina para aumentar el espacio libre.

Para calcular el indicador, los autores emplean los conceptos de Espacio Abierto, Espacio Semi-Abierto y el ratio k , que se define en la ecuación (3.27) y que mide la forma que adoptan las actividades en una determinada configuración.

Las cuestiones dignas de consideración en el desarrollo del indicador de diafanidad son:

- Existencia de tabiques o pilares.
- Numero de tabiques y pilares.
- Localización y tamaño de los tabiques y pilares.
- Factor de forma de de cada sub-área.

Los autores proponen emplear dos tipos de medida:

Medida 1. Empleando la siguiente expresión:

$$\text{Diafanidad}_1 = \frac{\sum \left[(EA) \cdot (\text{factor de forma})^{0.5} + (ESA) \cdot (\text{factor de forma})^{0.5} / [(n^\circ \text{ columnas}) + 1]^{1/3} \right]}{n^\circ \text{ de partes}} \quad (3.4)$$

Medida 2. Se emplean dos expresiones, según existan o no tabiques.

Si existen tabiques:

$$\text{Diafanidad}_2 = (\text{ratio } k_{\text{comp}})^{1/5} \cdot \text{Diafanidad}_1 \quad (3.5)$$

Si no existen tabiques:

$$\text{Diafanidad}_2 = (EA) \cdot (\text{ratio } k)^{1/5} \text{ o } \frac{(ESA) \cdot (\text{ratio } k)^{1/5}}{(n^\circ \text{ columnas} + 1)^{1/3}} \quad (3.6)$$

En el artículo de (Lin y Sharp 1999a) calculan los indicadores para 16 configuraciones generales, con tabiques y pilares intermedios.

Utilización y suficiencia espacial

En este criterio, (Lin y Sharp 1999a) recogen dos aspectos de interés en el problema:

- El primero es proporcionar un espacio definido para cada actividad, lo que denominan *Space Sufficiency*.
- El segundo es examinar la efectividad de la utilización espacial en dos y tres dimensiones. El objetivo es determinar si el espacio de la planta está sobreutilizado o infrautilizado.

La descripción de este indicador se amplía en el apartado 3.2.2.3, pues es un factor de aprovechamiento del área.

Pasillos

Este indicador mide la efectividad de la distribución de los pasillos en la planta. Hay dos tipos de pasillos:

- Los pasillos que se desarrollan debido a las necesidades de construcción del edificio.
- Los pasillos que se colocan en el layout de detalle y que pueden ser dispuestos libremente sin las ataduras del edificio.

Solo se tienen en cuenta los pasillos de cierta entidad. Se definen 6 objetivos en el sistema de implantación de los pasillos, con los que se calcula el indicador:

- Área servida por el pasillo
- Facilidad de acceso
- Rutas alternativas
- Intersecciones
- Forma de la actividad
- Rectitud del pasillo

Establecen un indicador en el que influyen la forma de las actividades, el número de cruces del pasillo, así como de su longitud. Este indicador puede ser muy interesante en el caso de abordar el problema de distribución en planta con pasillos, que no es objeto de la presente investigación.

Distancia y densidad del volumen

Este indicador se plantea para estimar la densidad del movimiento de material entre diferentes actividades, para alcanzar los requerimientos de producción.

Hay tres tipos de movimiento entre actividades:

1. Materias primas, componentes y producto acabado
2. Trabajo de papeleo
3. Movimiento de personal (ajeno al trabajo)

El más importante es el primero, pues los otros se cubren con distancias cortas y poco significativas. La densidad del movimiento de material (DMM) se puede representar de dos formas:

1. El volumen de material movido en los pasillos:

$$DMM = \sum_{i=1}^n \sum_{j=1}^n Vol_{ij} \cdot d_{ij} \quad (3.7)$$

Donde: Vol_{ij} es el volumen de material entre las actividades i, j

Los autores presentan una variación del indicador para el caso en el que existan diferentes plantas.

2. Tiempo gastado para mover el material:

$$DMM = \sum_{i=1}^n \sum_{j=1}^n (t_{ij} + \text{tiempo carga} + \text{tiempo descarga}) \quad (3.8)$$

Robustez del sistema de mantenimiento

El objetivo del indicador es estimar la robustez del sistema de mantenimiento para ajustar posible cambios y satisfacer diferentes requerimientos de capacidad productiva. Los autores exponen que la **flexibilidad** puede ser evaluada mediante este indicador.

Hacen hincapié en que un correcto sistema de mantenimiento debe cumplir con las siguientes premisas:

- Estandarización de la maquinaria.
- Capacidad del sistema de mantenimiento.
- Utilización del sistema. Proponen calcular un ratio de utilización del sistema de mantenimiento (o de cada parte del mismo).

Para realizar el cálculo del indicador, se basan en varios factores, todos ellos referidos a los diferentes subsistemas de la configuración, en nuestro caso habría que aplicarlo a las diferentes actividades que componen el problema.

- Numero de subsistemas.
- Capacidad de cada subsistema, medido en número de unidades que puede producir.
- Aptitud de cada subsistema, que tiene en cuenta el número de operaciones que puede realizar el mismo.

Con este indicador es complicado determinar la flexibilidad, pues permite calcular capacidades de los subsistemas, pero requiere de una gran cantidad de datos que en la formulación habitual del problema de distribución en planta no se facilitan.

Expansión de edificios

En este indicador, los autores estiman la facilidad para poder ampliar el espacio ocupado por los edificios o añadir actividades al existente. Para realizar el cálculo del indicador se tienen en cuenta dos factores:

- Área disponible para la expansión del edificio:

$$\text{Ind.AREA} = \text{Area exterior disponible} / \text{Area actual} \quad (3.9)$$

- Trastornos derivados de la ampliación. En esta parte se incluyen todos los problemas que puedan ocasionar a la producción las obras de ampliación del edificio productivo. Es un indicador cualitativo en el que 1 representa la peor situación posible.

3.2.2.1.4 Circulación

Al mismo nivel que la calidad geométrica de cada una de las soluciones generadas (tanto a nivel individual de cada una de las actividades, como a nivel global de la configuración del *layout*) se puede situar la calidad de las soluciones valorando el flujo de materiales que existe en los “pasillos” de la configuración propuesta.

En la bibliografía consultada, no se ha encontrado ninguna formulación cuantitativa de un indicador que mida este flujo de materiales en los pasillos, algo equivalente al tráfico por las calles de una ciudad o el fluido por una red de tuberías.

Parece lógico pensar que cuanto menor sea el tráfico por los pasillos de una planta, menores serán los riesgos de incidencias en el transporte de los materiales y, en general, en los servicios auxiliares que los rodean (mano de obra, utillajes...). Además, si el tráfico es de poca intensidad por los pasillos, querrá decir que las actividades con una mayor relación estarán más próximas y las que tengan una menor relación (en términos de flujo) se encontrarán más alejadas.

En la presente investigación se propone un nuevo indicador, que evalúe cuantitativamente este tráfico en los pasillos, se define la **circulación (τ)** como el tráfico de materiales por los pasillos de una determinada configuración, y se formula según la expresión (3.10):

$$\tau = \frac{\sum_{i=1}^n \sum_{j=1}^n (1 - b_{ij}) \cdot f_{ij}}{\sum_{i=1}^n \sum_{j=1}^n f_{ij}} \quad (3.10)$$

Donde: b_{ij} se obtiene de la matriz de fronteras, siendo 1 si las actividades i y j tienen frontera común, y 0 si no tienen frontera común.

f_{ij} es el flujo entre las actividades i y j .

De esta manera, si la posición que ocupan dos actividades cualquiera (i, j) es contigua, el flujo de materiales entre ambas no es tenido en cuenta en el sumatorio, ya que se considera que el “consumo de pasillo” (o circulación) generado por la interacción entre ambas actividades es nulo (actividades k y l de la Figura 3.2.4).

Sin embargo, si las actividades no comparten frontera, el trasiego de materiales por la interacción entre ambas actividades es tenida en cuenta. Por tanto entra en el sumatorio de la expresión del indicador de circulación τ de la configuración (tal y como ocurre entre las actividades k y p de la Figura 3.2.4). Para normalizar el indicador, se divide por el flujo total de materiales entre las distintas actividades de la planta.

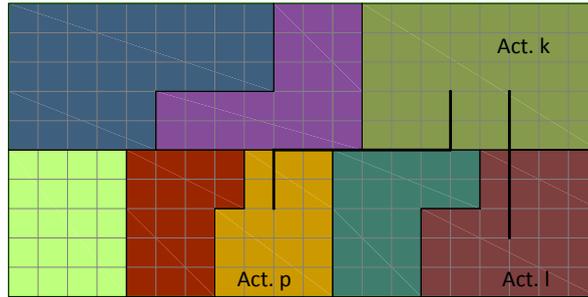


Figura 3.2.4 Circulación en una determinada configuración.

Tal y como se ha comentado en párrafos anteriores, éste es un *Indicador de Configuración*, puesto que la circulación únicamente se puede entender como un concepto global de la configuración de la planta, pues se necesita el flujo entre actividades para evaluar el indicador.

Una planta será más eficiente y segura en términos de riesgos laborales, cuanto menor sea la circulación existente en sus pasillos. Por tanto se buscarán, a lo largo de la presente investigación, distribuciones en planta que minimicen la circulación en los pasillos (τ) de la misma.

3.2.2.2 Indicadores Geométricos

Uno de los aspectos que tiene una mayor importancia a la hora de establecer la calidad de una solución al problema de distribución en planta es la calidad formal de la misma, pues el proceso de optimización siempre tiende a soluciones que, pese a ser excelentes desde el punto de vista del coste de transporte de materiales no dejan de ser aberraciones formales al problema de optimización.

Si no se tienen en consideración estos aspectos formales se obtienen soluciones no factibles desde el punto de vista práctico, y que tienen como máxima expresión las configuraciones “*sándwich*” y “*diana*”, mostradas en la Figura 3.2.5 y que fueron expuestas en (Contero 1995).

El algoritmo de optimización busca soluciones de este tipo, en el que las distancias se minimizan al tomar como métrica la distancia entre centroides. Este tipo de problemas tiene una mayor incidencia cuando se discretiza el dominio y se realiza un relleno de las casillas, y estos efectos se pueden paliar empleando métricas más exactas como puede ser la métrica EDIST, explicada en el punto 2.2.4.

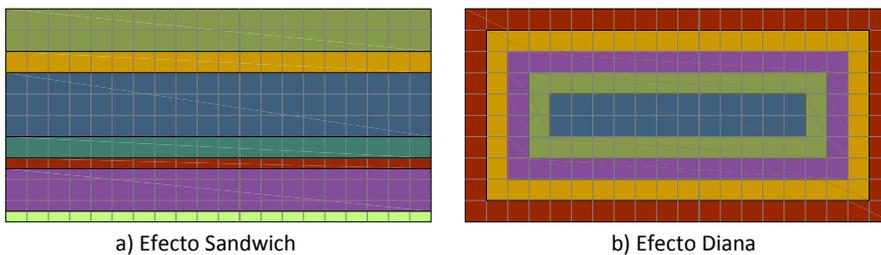


Figura 3.2.5 Degeneraciones formales.

Según se puede observar, la suposición de que el coste es directamente proporcional a la distancia entre los centros de gravedad, puede desvirtuar la solución obtenida, llegando hasta soluciones como la mostrada en b), que pese a tener un coste de transporte de materias nulo, no es factible desde un punto de vista práctico.

Asimismo, se puede llegar a soluciones en los que el ratio alto-ancho de cada una de las actividades es excesivamente elevado, llegando a soluciones tipo *sándwich* como la que se muestra en a) y que tiene un coste extremadamente bajo, aunque su factibilidad es también nula, pues las actividades no se pueden desarrollar en áreas tan alargadas.

Algunas de las mejores soluciones desde el punto de vista del coste que se pueden encontrar en la bibliografía sufren esta degeneración como las TS1, TS2 y TS3 de (Tate y Smith 1995) tal y como se puede ver en la Figura 3.2.6.

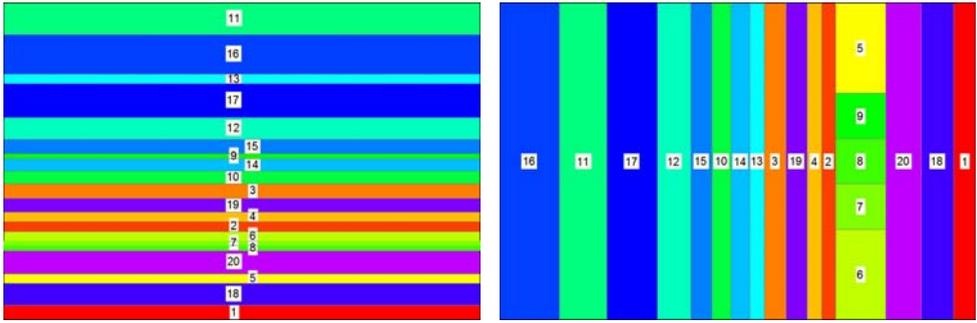


Figura 3.2.6 Algunas soluciones óptimas de (Tate y Smith 1995).

Con la finalidad de controlar todos estos problemas, surgidos fundamentalmente de la utilización de un modelo geométrico discreto y de métricas basadas en la distancia entre centroides, se definen una serie de indicadores geométricos. Además, las soluciones que tienen unas actividades con formas regulares son las que alcanzan una mayor flexibilidad geométrica ya que permiten una mejor distribución 2D.

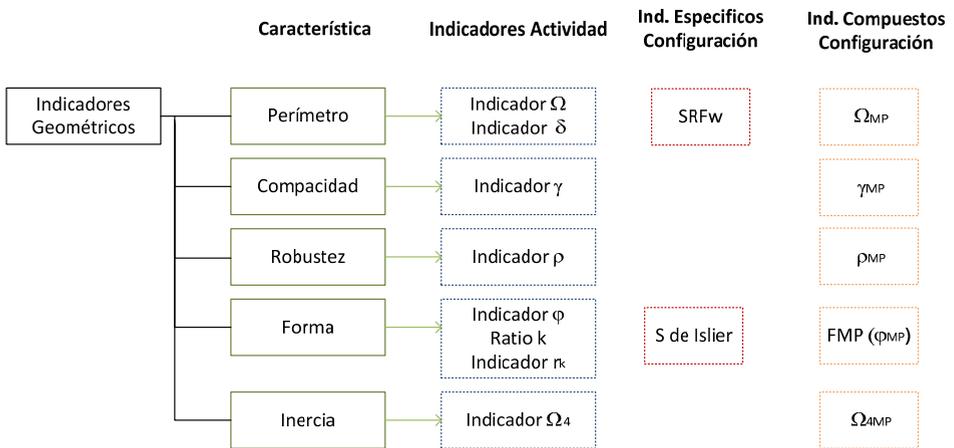


Figura 3.2.7 Indicadores geométricos en el problema de distribución en planta.

En esta parte del estudio se pone una especial atención, puesto que al trabajar con un relleno discreto de las actividades, los indicadores geométricos constituyen una herramienta fundamental para obtener soluciones eficientes desde el punto de vista formal.

Se describirán las diferentes características geométricas y los indicadores tanto a nivel de actividad como de la configuración de una determinada solución. En algunos casos, aquellos que se consideran más relevantes, se estudia la influencia que tiene el tamaño de la actividad en los valores máximo y mínimo que puede adoptar el indicador, siempre para el caso de un dominio discreto, con n casillas.

3.2.2.2.1 Indicadores de Perímetro

Se distinguirá, tal y como se ha comentado con anterioridad entre los indicadores relativos a cada una de las actividades de la planta y aquellos que evalúan la calidad de la solución global (configuración).

Indicadores de Actividad

En la bibliografía se pueden encontrar diferentes indicadores que emplean el perímetro de las actividades para controlar la calidad formal de las actividades, así como de la solución. Mientras que el indicador Ω es útil para configuraciones en las que el relleno se realiza de manera controlada, el indicador δ es más apropiado para situaciones en las que el relleno se hace mediante curvas de Hilbert (SFC).

Indicador Ω

El indicador de perímetro aparece por primera vez, aplicado al problema de distribución en planta, en (Bozer y Meller 1994) donde se inspiraban en un artículo de procesamiento de imágenes (Freeman 1974). Bozer lo expresa como Ω_i , y se basa en el hecho de que cuanto mayor sea el perímetro de la actividad, menor será la calidad formal de la misma.

Posteriormente este indicador aparece con idéntica formulación, pero bajo el nombre de SR (*Shape Ratio*) en (Wang, Hu y Ku 2005), como parte básica de un indicador global de configuración.

El caso ideal, en el que el perímetro es mínimo, se da cuando la actividad adquiere una forma cuadrada, de lado \sqrt{A} . El coeficiente relaciona el perímetro de la actividad P_i con el perímetro del cuadrado ideal que albergaría la misma, P_i^* .

$$\begin{aligned} P_i^* &= 4\sqrt{A_i} \\ \Omega_i &= \frac{P_i/A_i}{P_i^*/A_i} = \frac{P_i}{4\sqrt{A_i}} \end{aligned} \quad (3.11)$$

Bozer fija un valor límite para este indicador, estableciendo que valores superiores a 1.5 corresponden a actividades con una calidad formal manifiestamente negativas. En el caso de emplear dominios discretos, el valor mínimo del indicador puede no alcanzar la unidad, dado que el tamaño de la discretización puede hacer imposible llegar a este valor.

Uno de los problemas que tiene el indicador es que no tiene un valor normalizado, puesto que el mínimo es 1 (o está muy cerca) pero el máximo, que se corresponde con la configuración en "columna" tiene un valor de:

$$\Omega_{\max,i}(n) = \frac{2 \cdot n + 2}{4\sqrt{A_i}} = \frac{n + 1}{2 \cdot \sqrt{A_i}} \quad (3.12)$$

Para el caso de una actividad de tamaño medio $\Omega_1(25)=2.6$ y para una grande $\Omega_1(100)=5.05$.

Una posible solución para realizar la normalización del indicador es emplear su inverso Ω^{-1} . De esta forma el objetivo sería maximizar el indicador, siendo la unidad el valor óptimo y su valor mínimo:

$$\Omega_1^{-1}(n) = \frac{2\sqrt{A_1}}{n+1} \quad \text{cumpliendo que} \quad \lim_{n \rightarrow \infty} \Omega^{-1}(n) = 0 \quad (3.13)$$

Según lo expuesto por Bozer, el mínimo valor de Ω^{-1} para que la actividad sea formalmente aceptable será $\Omega = 1.5 \rightarrow \Omega^{-1} = 0.67$.

Estudiando el caso de diferentes configuraciones para una actividad de 9 casillas, se obtienen los valores mostrados en la Figura 3.2.8.

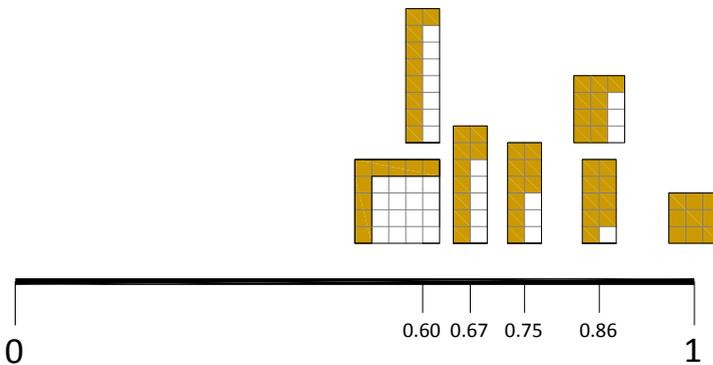


Figura 3.2.8 Diferentes valores de Ω_1^{-1} para una actividad de 9 casillas.

A continuación se realiza un estudio de la dependencia del indicador de perímetro con el número de casillas de área que tenga la actividad, siempre en el caso de un relleno discreto del dominio.

Para realizar este estudio se deben conocer, en primer lugar, que límites adquiere el indicador para actividades de diferente número de casillas, en primer lugar se determina el valor mínimo del indicador para una actividad de n casillas.

El valor mínimo se corresponderá con una configuración en la que la actividad se dispone en una única columna, con lo cual, la altura de la misma será precisamente el número de casillas n , en este caso, el valor numérico del mínimo de este indicador será el establecido en (3.14).

$$\Omega_{\min}^{-1}(n) = \frac{4 \cdot \sqrt{n}}{2 + 2 \cdot n} = \frac{2 \cdot \sqrt{n}}{n + 1} \quad (3.14)$$

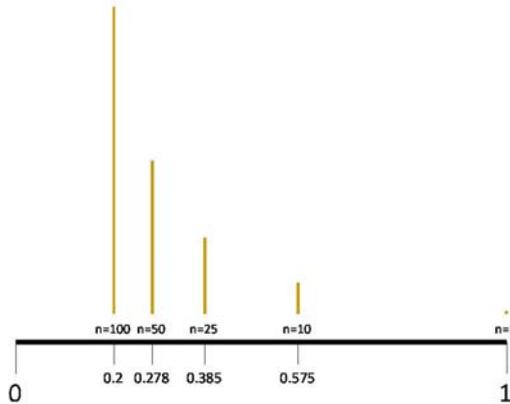


Figura 3.2.9 Valores mínimos de Ω_i^{-1} para actividades de diferente área.

El valor máximo del indicador, en función del número de casillas, será aquel que se acerque más a la forma cuadrada de la actividad, en cuyo caso se alcanzará el valor unidad, y en función de lo alejado que esté el siguiente cuadrado, el valor se acerca a la unidad, sin alcanzarse.

En la Figura 3.2.10, se puede observar como varían los valores máximo y mínimo del indicador, en función del área (n) de la actividad. Remarcamos un hecho que ha de tenerse en cuenta, como es que un mismo valor del indicador, puede significar estar muy próximo al mínimo (si el área de la actividad es muy pequeña) o estar en una situación equidistante al máximo, (si la actividad tiene un área elevada). A medida que el área de la actividad crece, el valor mínimo se estabiliza entorno al valor del indicador de 0.1 para áreas de 500 unidades. Destacar que los problemas test, como el de Armour y Buffa de 20 actividades, tienen un área máxima de 75 unidades.

Otro detalle a tener en cuenta es que en el planteamiento del presente trabajo se pretende conseguir un valor lo más elevado posible del indicador de perímetro (Ω^{-1}), por tanto no es de gran importancia la variación del valor mínimo con el número de casillas que tenga la actividad. Sin embargo sí que se debe tener en cuenta que el valor máximo de este indicador se ve influenciado por el número de casillas que tenga la actividad. Así, una actividad con un área de 4, 9, 16, 25 unidades puede alcanzar el valor máximo de $\Omega^{-1} = 1$ y sin embargo áreas de 2, 8, 18 unidades como máximo alcanzarán el valor de $\Omega^{-1} = 0.9428$.

Se puede establecer un indicador de perímetro independiente del área de la actividad, y que se formula mediante la expresión (3.15):

$$\tilde{\Omega}^{-1}(n) = \frac{\Omega^{-1}(n) - \Omega_{\min}^{-1}(n)}{\Omega_{\max}^{-1}(n) - \Omega_{\min}^{-1}(n)} \quad (3.15)$$

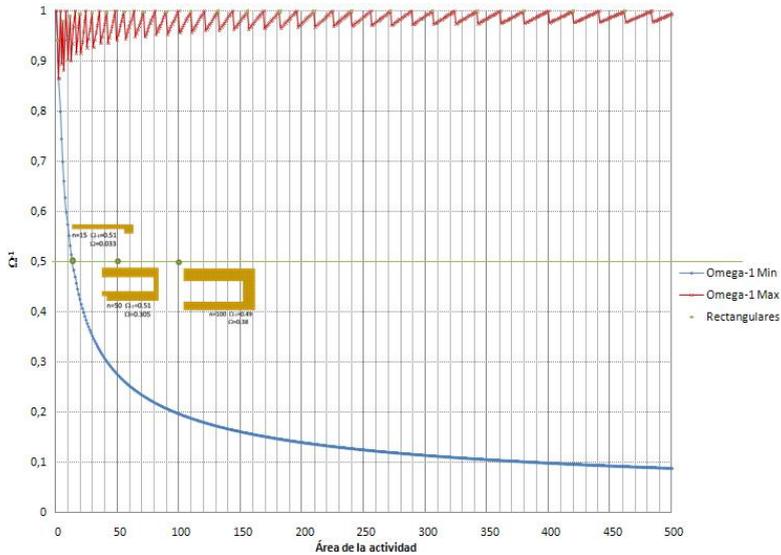


Figura 3.2.10 Variación del indicador Ω^{-1} mínimo y máximo con el número de casillas.

En este caso, tal y como se puede observar en la Figura 3.2.11, y para un valor de $\Omega^{-1} = 0.5$, se pueden obtener los valores correspondientes al indicador corregido para diferentes áreas de la actividad (línea morada).

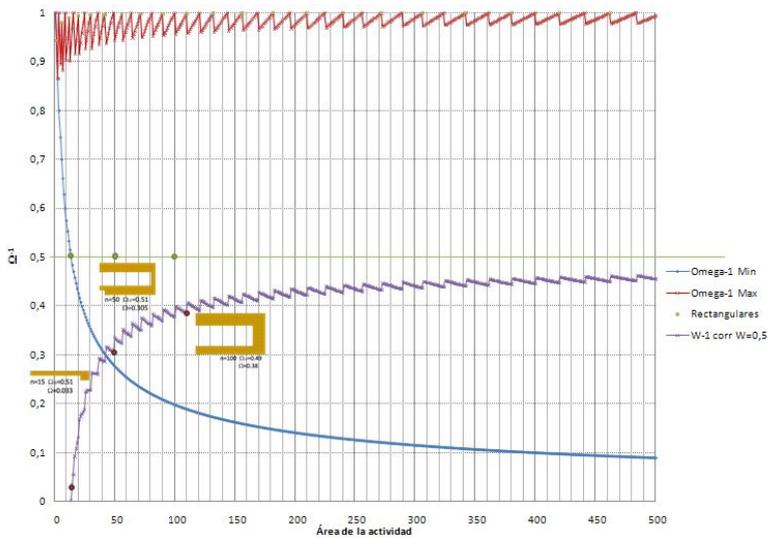


Figura 3.2.11 Evolución del indicador $\tilde{\Omega}^{-1}(n)$ para $\Omega^{-1}=0.5$.

Indicador δ

El indicador δ aparece en (Lin y Sharp 1999a) y se formula como la relación entre el perímetro de la actividad y el perímetro del rectángulo que la engloba completamente.

$$\delta_i = \frac{P_i}{P_{\text{rectángulo inscribe}_i}} \geq 1 \tag{3.16}$$

Este es un indicador que tiene una fiabilidad muy baja, pues aparecen situaciones como la mostrada en los casos a) y b) de la Figura 3.2.12, en la que el valor del indicador es idéntico e igual al mínimo ($\delta = 1$), aunque la primera solución es mucho mejor que la segunda. Tal y como se puede observar en c) y d) en los casos en los que el relleno se realice con SFC completamente libres, éste indicador puede ser útil, dado que si la forma obtenida está muy degenerada, el indicador es superior a la unidad.

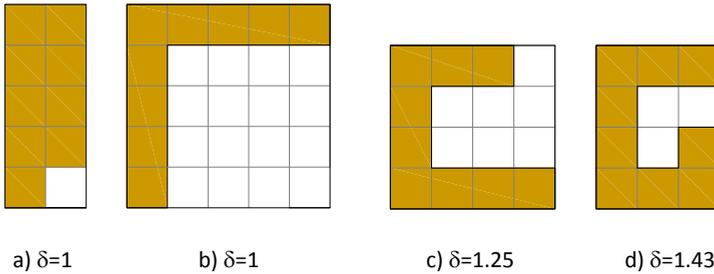


Figura 3.2.12 Evaluación del indicador δ para varias actividades de $n=9$.

El indicador tampoco es capaz de determinar si la actividad ha sido implantada de manera inconexa, es decir, si se ha producido rotura a la hora de la colocación de la misma. Tal y como se puede observar en la Figura 3.2.13, todas las actividades tienen un ($\delta = 1$). Por tanto no se empleará en la presente investigación, al no considerarlo un buen referente.

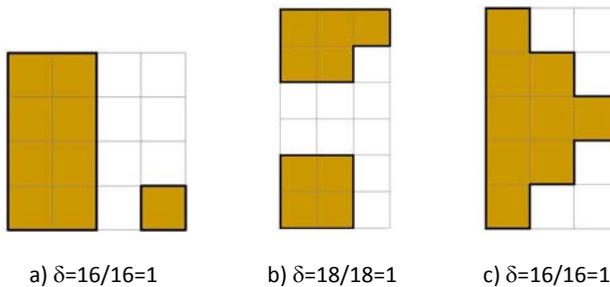


Figura 3.2.13 Evaluación del indicador δ en actividades con rotura.

Indicadores de Configuración

En las referencias se puede encontrar un indicador específico de la configuración basado en el perímetro de las actividades, y también se puede extender el indicador de actividad a toda la configuración.

SRF_{whole}

En (Wang, Hu y Ku 2005) aparece un indicador global de la configuración denominado SRF_{whole} (*Shape Ratio Factor*) como parte de una función agregada multiplicativa con la que resuelve el problema de distribución en planta.

Los autores proponen emplear el indicador clásico de perímetro Ω , al que llaman SR, de cada una de las n actividades de la configuración, agregándolo en un indicador SRF_w, obtenido como la media geométrica de los mismos.

$$SRF_w = \left(\prod_{i=1}^n SR_i \right)^{1/n} = \left(\prod_{i=1}^n \frac{P_i}{4 \cdot \sqrt{A_i}} \right)^{1/n} \geq 1 \quad (3.17)$$

Para el caso (ideal) en el que todas las actividades tuvieran una forma cuadrada, el indicador SRF_w adquiere un valor igual a la unidad, siendo éste el valor utópico del indicador. El valor de SRF_w obtenido debe de ser minimizado de la misma manera que era parte de una función objetivo multiplicativa que se minimiza en el artículo de Wang.

Extensión del indicador de actividad

Una segunda posibilidad para extender el indicador de perímetro de cada actividad a la configuración de la planta es, dado que lo que se pretende es obtener el mayor valor de $\Omega_i^{-1}(n)$, realizar la maximización del mínimo valor del indicador para cada una de las n actividades de la configuración, de esta manera se eleva el valor del indicador de perímetro global.

3.2.2.2 Indicadores de Compacidad

En el caso de emplear un modelo geométrico discreto, es de gran importancia la forma en la que la curva o procedimiento de relleno, configure el área destinada a cada actividad. Pueden configurarse actividades con formas altamente indeseables, comprometiendo, incluso, la implantación de las mismas. Para evitar estos problemas, se pueden emplear indicadores de compacidad de las actividades. A continuación se recogen los indicadores de compacidad encontrados en la bibliografía, distinguiendo entre los de actividad y los de configuración.

Indicador de Actividad

Compacidad γ

Este indicador geométrico de actividad fue definido y empleado en (Liggett y Mitchell 1981) como *Coherence Ratio*, en (Moon y McRoberts 1989) como *Shape Rate*, en (Raoot y Rakshit 1993) como *Shape Ratio*, en (Contero 1995) como Ω_2 , en (Lin y Sharp 1999a) como *Area Ratio* y posteriormente renombrado y empleado por (Gonzalez 2005) como *Compacidad (γ)*.

La compacidad de una actividad es el cociente entre el área de la actividad (A_i) y el área del rectángulo de menor área que es capaz de contenerla en su totalidad, tal y como se muestra en la Figura 3.2.14.

Numéricamente, la compacidad de la actividad i -ésima se puede expresar de la siguiente manera:

$$\gamma_i = \frac{\text{Área de la actividad } i}{\text{Área del rectángulo } i} = \frac{A_i}{a_i \times h_i}; \quad 0 < \gamma_i \leq 1 \quad (3.18)$$

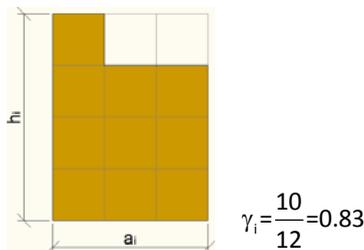


Figura 3.2.14 Cálculo de la compacidad de la actividad i -ésima.

El indicador fue criticado en (Bozer y Meller 1994), donde los autores presentaron el indicador de perímetro, precisando que si la curva de relleno empleada es muy complicada y da lugar a geometrías muy degeneradas, el indicador de perímetro es más efectivo para detectar estos casos.

Un valor de compacidad 1 indica actividades que rellenan de una forma compacta la superficie de la planta. Por el contrario, valores cercanos a 0 (nunca alcanzable), indican actividades muy disgregadas, y por tanto poco compactas.

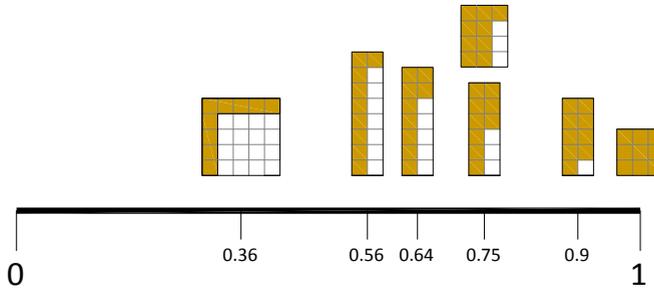


Figura 3.2.15 Diferentes valores de compacidad para una actividad de 9 casillas.

Este indicador no es de aplicación en modelos continuos, pues la forma en la que se realiza el relleno del área, es ya compacto de por sí, por tanto siempre $\gamma_i = 1$. En los modelos discretos, como el empleado en la presente investigación, si que puede aportar información muy útil, pues cuanto más compacta sea la actividad, mayor facilidad de implantación práctica tendrá la misma.

No obstante, la compacidad no controla la forma asignada a la actividad, pues puede ocurrir que actividades con $\gamma_i = 1$ tengan una forma no deseable desde el punto de vista de la implantación tal y como se puede ver en la Figura 3.2.16.

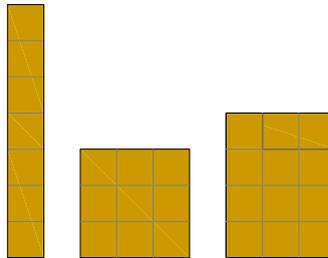


Figura 3.2.16 Configuraciones con $\gamma_i = 1$.

Con este indicador ocurre lo mismo que con el indicador de perímetro, el óptimo (y máximo) siempre es la unidad, aunque en este caso puede no corresponderse con una forma de la actividad aconsejable, mientras que el mínimo se corresponde con formas en “L” (tampoco aconsejables) y es dependiente del área de la actividad. En concreto, el mínimo valor de la compacidad en el caso de relleno discreto es:

$$\gamma = \frac{n}{x \cdot (n - x + 1)}; \quad \gamma_{\min} \text{ para } x = \frac{n+1}{2} \quad (3.19)$$

La evolución de estos dos valores con el tamaño de la actividad (n) es el mostrado en la Figura 3.2.17.

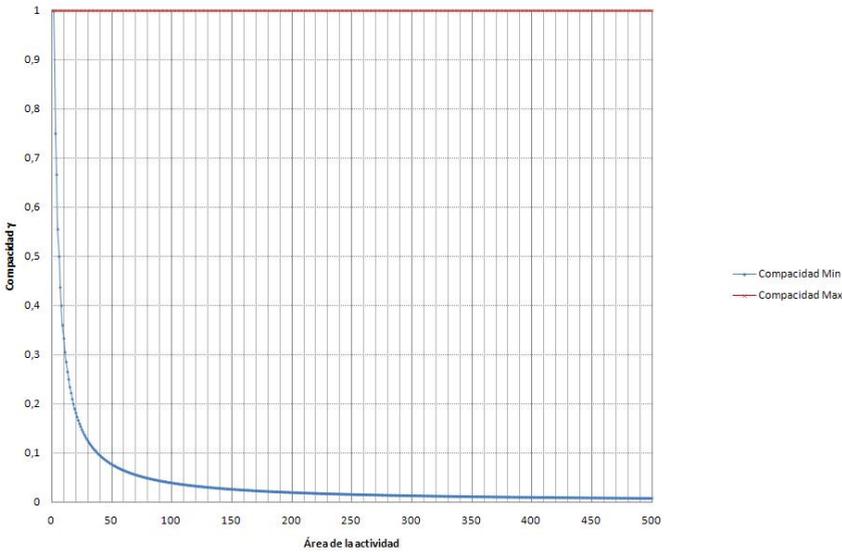


Figura 3.2.17 Evolución del indicador compacidad con el área.

Indicadores de Configuración

No existe en la bibliografía ningún indicador específico de la compacidad de una configuración, pudiéndose emplear como un indicador válido cualquiera de las siguientes opciones:

- Calculando un valor de compacidad media ponderada (γ_{MP}) para toda la configuración, quedando expresado como:

$$\gamma_{MP} = \frac{\sum_{i=1}^n A_i \cdot \gamma_i}{\sum_{i=1}^n A_i} \quad (3.20)$$

Donde: n es el número de actividades del problema.

A_i es el área de cada una de las n actividades.

- Otra posibilidad es maximizar la menor de las compacidades (γ_i) de la configuración, de esta manera, si la menor compacidad adquiere un valor muy elevado, el resto de compacidades serán aun mejores.

3.2.2.2.3 Indicadores de Robustez

Al igual que se ha realizado con el resto de indicadores, a continuación se presentan los indicadores de actividad y de configuración presentes en las referencias bibliográficas que abordan el problema de distribución en planta.

Indicadores de Actividad

Indicador ρ

Este indicador geométrico de actividad fue definido y empleado en (Liggett y Mitchell 1981) como *Proportion Ratio*, en (Contero 1995) como Ω_3 y posteriormente renombrado y empleado por (Gonzalez 2005) como *Robustez* (ρ_i). Posteriormente también fue empleado en (Aiello, Enea y Galante 2006) bajo el nombre de *Aspect Ratio* (γ_i).

Se define la robustez como el cociente entre el lado menor y el lado mayor del menor rectángulo que inscriba a la actividad (A_i), tal y como se muestra en la Figura 3.2.18. Al igual que con la compacidad, este indicador también fue criticado por Bozer.

La expresión numérica de la robustez queda definida como:

$$\rho_i = \frac{\text{Minima dimension rectangulo}}{\text{Maxima dimension rectangulo}} = \frac{\min(a_i, h_i)}{\max(a_i, h_i)}; \quad 0 < \rho_i \leq 1 \quad (3.21)$$

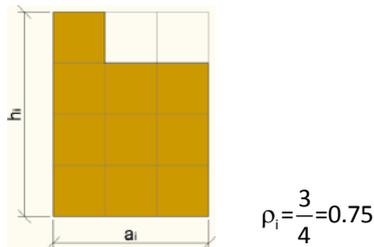


Figura 3.2.18 Robustez de la actividad i -ésima.

Un valor de robustez 1 indica que el área asignada a la actividad es cuadrada, por tanto su flexibilidad será mayor, mientras que valores cercanos a 0 (nunca alcanzable), indican actividades muy esbeltas o alargadas (configuración no deseada, pues su implantación es muy complicada y poco flexible).

En la Figura 3.2.19 se muestran los valores de robustez asociada a las 7 configuraciones de ejemplo de la actividad de 9 unidades de área ($n_i=9$), en la que los valores más bajos son los menos apropiados.

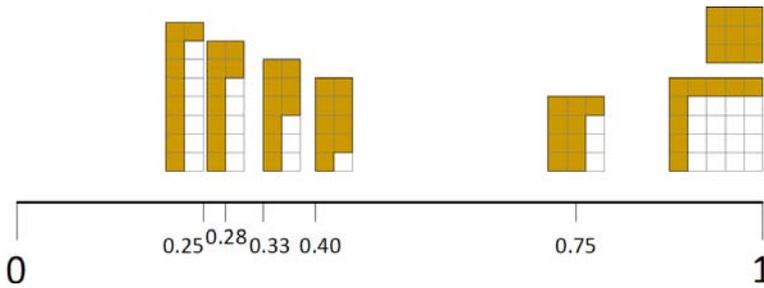


Figura 3.2.19 Diferentes valores de robustez para una actividad de 9 casillas.

Este indicador es de aplicación tanto en modelos discretos como continuos, y fue empleado por autores como (Diego-Más 2006). La aplicabilidad en los modelos continuos de este indicador es directa, pues el relleno del espacio es compacto, sin embargo, en los modelos discretos, al ser el relleno no compacto pueden darse situaciones muy contradictorias, como el tener actividades con una robustez máxima ($\rho_i = 1$) excesivamente disgregadas, tal y como se muestra en la Figura 3.2.20.

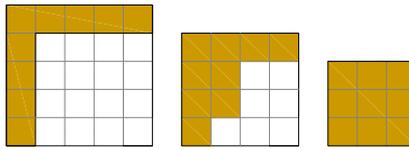


Figura 3.2.20 Configuraciones con $\rho_i=1$.

Para el caso de modelos discretos, los límites del indicador serán:

$$\rho_{\min} = \frac{1}{n_i} \quad \rho_{\max} = 1 \quad (3.22)$$

Indicadores de Configuración

No existe en la bibliografía ningún indicador específico de la robustez de una configuración, pudiéndose emplear como un indicador válido cualquiera de las siguientes opciones:

- Definiendo un valor de robustez media ponderada (ρ_{MP}) para toda la configuración, quedando expresada como:

$$\rho_{MP} = \frac{\sum_{i=1}^n A_i \cdot \rho_i}{\sum_{i=1}^n A_i} \quad (3.23)$$

Donde: n es el número de actividades del problema.

- Otra posible estrategia es maximizar la menor de las robusteces de la configuración (ρ_i), de esta manera, si la menor robustez adquiere un valor muy elevado, el resto de robusteces serán aun mejores. Expresado numéricamente, el objetivo será:

3.2.2.2.4 Indicadores de Forma

Ni la compacidad ni la robustez, proporcionan por separado una garantía de que las soluciones tienen una calidad formal elevada, pues pueden darse soluciones con buenos valores de los indicadores que realmente no lo sean. A continuación se resumen los indicadores de actividad y de configuración encontrados en la bibliografía.

Indicadores de Actividad

Forma φ

En (Gonzalez 2005) se definió un indicador que combina la compacidad y la robustez para generar uno nuevo que potencie los beneficios de ambos, la llamada forma de la actividad (φ_i), que queda definida como el producto de la robustez y la compacidad de la actividad. Geométricamente, la forma φ de una actividad se obtiene del cociente entre el área de la actividad y el cuadrado del lado mayor del rectángulo que puede contener la actividad.

La expresión matemática del indicador forma es:

$$\varphi_i = \gamma_i \cdot \rho_i = \frac{A_i}{a_i \times h_i} \cdot \frac{\min(a_i, h_i)}{\max(a_i, h_i)} = \frac{A_i}{\max(a_i, h_i)^2} \quad (3.24)$$

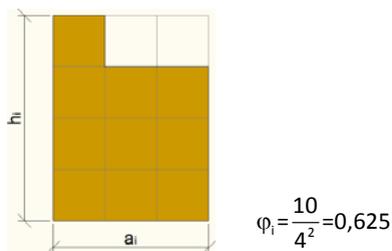


Figura 3.2.21 Determinación del indicador forma de una actividad.

Un valor de forma 1 indica que la actividad rellena completamente un rectángulo mientras que valores cercanos a 0 (nunca alcanzable), indican actividades esbeltas y poco compactas o disgregadas.

Este indicador es de aplicación tanto en modelos continuos como en discretos aunque en los modelos continuos es análogo a la robustez, pues la compacidad en este caso es siempre igual a la unidad. En modelos discretos, este indicador es más fiable que la robustez y la compacidad, pues palia alguno de los problemas que tenían los indicadores expuestos con anterioridad, aunque no solventa los problemas de las actividades en "L".

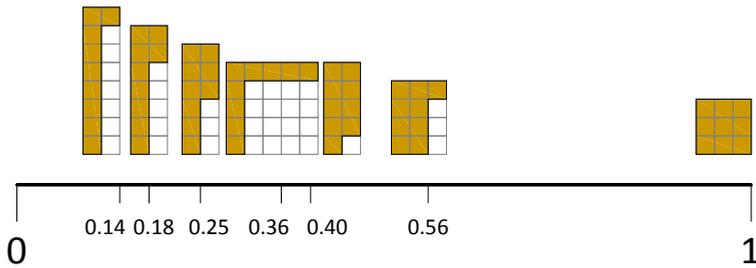


Figura 3.2.22 Diferentes valores de forma para una actividad de 9 casillas.

En la Figura 3.2.23, se pueden observar dos posibles configuraciones que son significativamente diferentes, la solución a) es formalmente mejor que la solución b) y sin embargo ambas tienen un valor similar del indicador.

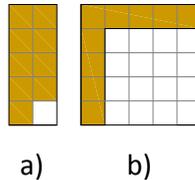


Figura 3.2.23 Configuraciones con $\varphi_a=0.4$ y $\varphi_b=0.36$.

Para evitar esta situación, se puede reformular el indicador, penalizando aquellas configuraciones en las que la compacidad es manifiestamente negativa, empleando una expresión del tipo:

$$\varphi(k) = \rho \cdot \gamma^k \tag{3.25}$$

Si se fija un valor de $k=2$, los valores del indicador para las actividades de ejemplo quedan mucho más concentrados, aunque si que se penaliza a aquellas actividades que tienden a adquirir formas irregulares, como el caso b) señalado anteriormente.

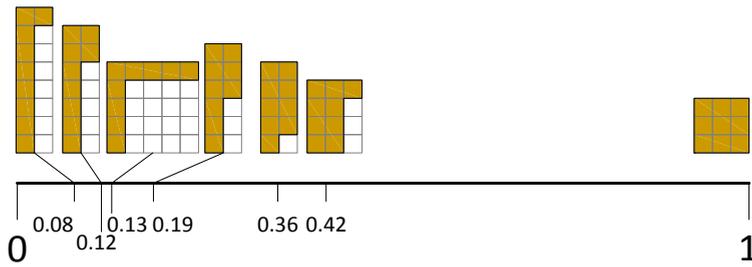


Figura 3.2.24 Valores de forma modificada con un valor de k=2.

En el caso discreto, el indicador de forma se comporta de la misma manera que la compacidad y la robustez, sus valores límites serán:

$$\varphi_{\min} = \frac{1}{n_i} \quad \varphi_{\max} \cong 1 \quad (3.26)$$

La evolución de la forma máxima y mínima con el tamaño de la actividad es el mostrado en la Figura 3.2.25.

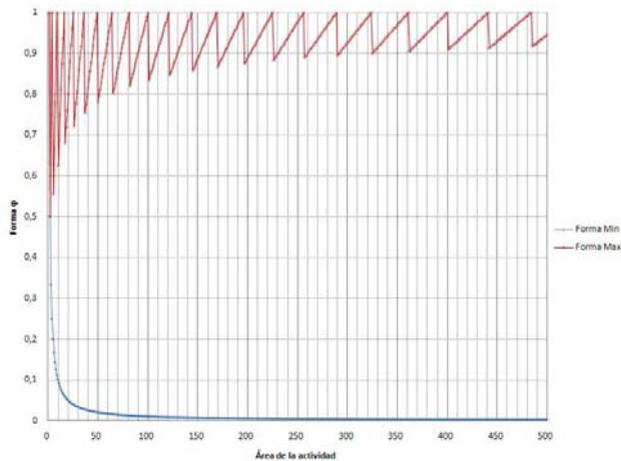


Figura 3.2.25 Evolución del indicador forma φ con el área.

Ratio k

Una alternativa al indicador de forma mencionado anteriormente se puede encontrar (Lin y Sharp 1999a) donde los autores plantean indicadores como la diafanidad (apartado 3.2.2.1.3), y el ratio k que acumula algunos de los indicadores comentados anteriormente.

El ratio k es el producto de la compacidad y robustez (o lo que es lo mismo, el indicador de forma) dividido por el indicador de perímetro δ , por tanto su formulación será:

$$\text{ratio } k_i = \frac{\gamma_i \cdot P_i}{\delta_i} = \frac{\varphi_i}{\delta_i}$$

Tal y como se describió en el apartado correspondiente al indicador δ , este únicamente es significativo para situaciones en las que el sistema de relleno del espacio permite que la forma de la actividad esté extremadamente degenerada, situación que no se alcanzará con el sistema de relleno que se aplicarán en la presente investigación.

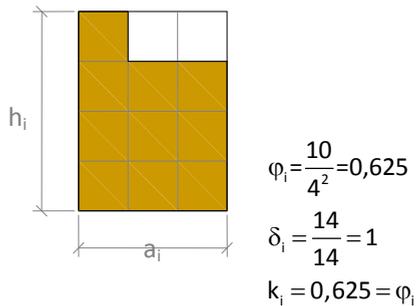
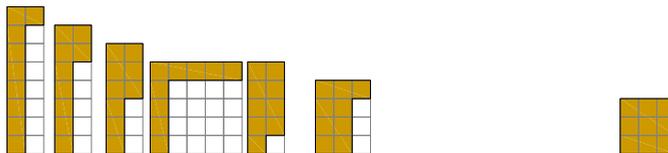


Figura 3.2.26 Cálculo del ratio k de una actividad.

Si se calcula el ratio k para las diferentes formas de la actividad de 9 casillas, igual que se hizo en el resto de indicadores, se observa que el valor coincide con la forma, puesto que en todos los casos el indicador $\delta=1$.



Factor de Forma de Islier (s)

Una de las aportaciones más originales al problema distribución en planta de la última década es la realizada en (Islier 1998), en la que el autor aborda el problema mediante una función objetivo multiplicativa compuesta por tres factores: carga, desviación y lo que es más interesante un factor de forma s. La función objetivo es la siguiente:

$$\text{Max} \left(\frac{t}{s \cdot h} \right) \tag{3.28}$$

Los tres factores están referidos a la solución final, y no se corresponden a cada una de las actividades que las conforman, por tanto, son indicadores de configuración.

Sin embargo, para el cálculo del factor de forma de configuración (s) se emplean el valor r_k , que puede ser considerado como un indicador de forma de cada una de las actividades, puesto que sí es una característica de la forma de la actividad y se obtiene de la siguiente manera:

$$r_k = \sum_{p \in S_k} u_{pk}^2 \tag{3.29}$$

Donde: u_{pk} : Es la distancia Manhattan entre la celda p y el centro de gravedad de la actividad k, siempre que la celda p pertenezca al dominio de la actividad k.

La actividad de 9 casillas, comentada con anterioridad, adopta un valor de este indicador:

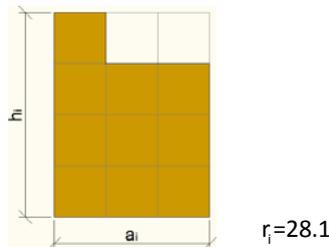


Figura 3.2.28 Factor r_i de la actividad i-ésima.

Realizando las operaciones análogas con el resto de formas adoptadas por la actividad de 9 casillas, se obtienen los siguientes valores:

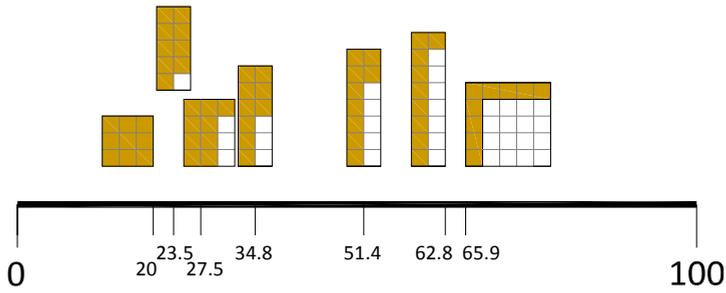


Figura 3.2.29 Diferentes valores de r_k para una actividad de 9 casillas.

En este caso, el factor r_k varía sus valores límite en función del número de unidades de área que tenga, no es un valor que esté acotado y como se puede observar en la anterior figura, varía entre 0 y 100.

Un problema que puede aparecer al emplear este factor de actividad a la hora de realizar el estudio multiobjetivo es que el indicador varía en función del área de la actividad, es decir, si la forma ideal es la cuadrada, el valor del coeficiente r_k no da valores iguales para diferentes áreas como se puede ver en la Figura 3.2.30.

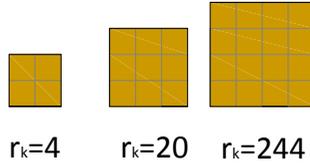


Figura 3.2.30 Factor r_k de actividades cuadradas.

Debido a este problema, no se considerará en apartados posteriores de esta investigación.

Indicadores de Configuración

Si se extrapolan estos indicadores a toda la configuración de la solución, se pueden emplear cualquiera de las siguientes estrategias:

- En (Gonzalez 2005) se plantea un indicador de la configuración global al que llama Forma Media Ponderada (φ_{MP}), que define como la suma ponderada de todas las formas de las actividades de una determinada configuración, y que se obtiene numéricamente de la siguiente expresión:

$$\varphi_{MP} = \frac{\sum_{i=1}^n A_i \cdot \gamma_i \cdot \rho_i}{\text{Area del recinto}} = \frac{\sum_{i=1}^n A_i \cdot \varphi_i}{\sum_{i=1}^n A_i} \quad (3.30)$$

Donde: n es el número de actividades del problema.

- También es posible maximizar la menor de las formas de la configuración (φ_1), de esta manera, si la actividad con un peor valor de forma adquiere un valor muy elevado, el resto de formas serán aun mejores.
- Dentro de los indicadores de configuración que consideran la forma, si que se puede considerar el factor s introducido por (Islier 1998) y que queda definido de la siguiente manera:

$$s = \frac{\sum_{k=1}^n r_k}{\sum_{i=1}^a \sum_{j=1}^h \sum_{k=1}^n a_{ijk}} \quad (3.31)$$

- Donde: a_{ijk} : Variable de asignación que es igual a 1 si la celda i,j -ésima está ocupada por la actividad k (y 0 en caso contrario)
- a : Número de filas de la discretización del dominio.
- h : Número de columnas de la discretización del dominio.

3.2.2.2.5 Indicadores de Inercia

Por último se recogen los indicadores que consideran la inercia de las actividades de una determinada configuración. Al igual que con el resto de indicadores, se realiza la diferencia entre aquellos que se centran en una única actividad y los que establecen un valor para toda la configuración.

Indicadores de Actividad

Indicador Ω_4

Otro indicador de la calidad formal de la solución fue propuesto por (Contero 1995) y tiene su fundamento en el momento polar de inercia de la actividad, como medida de la dispersión del área asociada a la misma. En este caso se emplea la expresión del momento polar de inercia respecto del centro de gravedad de la actividad:

$$I_i = \sum_{j=1}^{A_i} m_j \cdot d_j^2 \quad (3.32)$$

Siendo I_i el momento de inercia de la actividad i -ésima respecto de su centro de gravedad, A_i el área de la actividad i -ésima, m_j la masa asociada a la celda elemental y d_j la distancia de la celda j al centro de la gravedad de la actividad.

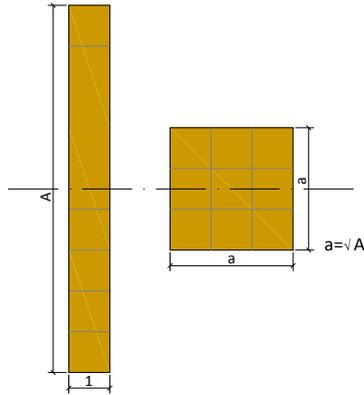
En el caso de un rectángulo de dimensiones $a \times b$, el momento polar de inercia respecto a su centro de gravedad valdrá:

$$I_{xy} = I_x + I_y = \frac{1}{12} \cdot a \cdot b^3 + \frac{1}{12} \cdot b \cdot a^3 = \frac{1}{12} \cdot (a \cdot b^3 + b \cdot a^3) \quad (3.33)$$

Una vez conocido el valor del momento polar de inercia respecto al centro de gravedad de la actividad, (Contero 1995) calcula un factor normalizado que permite valorar la calidad geométrica de la actividad. Para ello, es necesario conocer cuáles son los valores máximo y mínimo de inercia polar que puede adoptar una actividad de un área determinada. Estos casos se corresponden con una geometría alargada de ancho unidad y largo el número de casillas y una geometría cuadrada de lado $a = \sqrt{A}$.

El indicador de inercia, Ω_4 , es adimensional, y tiene en cuenta la desviación de la inercia de la actividad respecto a los valores máximo y mínimo que podría adoptar en una configuración discreta mencionados anteriormente y cuya expresión sería la siguiente:

$$\Omega_{4i} = \frac{I_i - I_{\min}}{I_{\max} - I_{\min}} ; 0 \leq \Omega_{4i} \leq 1 \quad (3.34)$$



$$I_{\max} = \frac{1}{12} \cdot (9^3 \cdot 1 + 9 \cdot 1^3) = 61.5 \quad I_{\min} = \frac{1}{12} \cdot (3 \cdot 3^3 + 3^3 \cdot 3) = 13.5$$

Figura 3.2.31 Valores significativos para una actividad de 9 casillas.

De esta manera, configuraciones cuadradas adoptan un coeficiente cercano a 0, mientras que geometrías más desfavorables adoptan un coeficiente más próximo a la unidad.

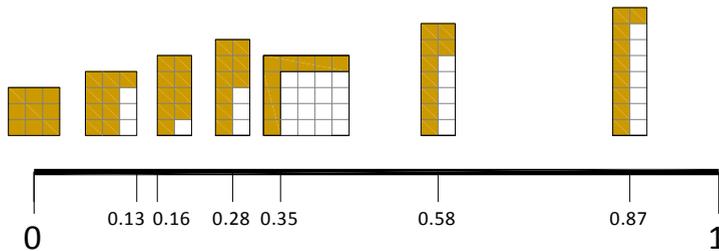


Figura 3.2.32 Diferentes valores de Ω_4 para una actividad de 9 casillas.

Indicadores de Configuración

No existe, en la bibliografía consultada sobre el problema de distribución en planta, ningún indicador de configuración de la solución que tenga como base el indicador de inercia propuesto por (Contero 1995). Podría emplearse cualquiera de las dos líneas que se han seguido con el resto de indicadores, bien minimizar el máximo de los Ω_4 o bien buscar un valor promedio ponderado de los indicadores de actividad.

$$\Omega_{4MP} = \frac{\sum_{i=1}^n A_i \cdot \Omega_{4i}}{\sum_{i=1}^n A_i} \quad (3.35)$$

3.2.2.3 Indicadores de aprovechamiento de área

Otra de las características geométricas a tener en cuenta es la relacionada con el aprovechamiento que se hace del recinto sobre el que se implanta la industria. Se puede abordar el problema de dos formas, en función de la relación del área del recinto A_R y la suma de las áreas de cada una de las actividades:

$$A_R \leftrightarrow \sum_{i=1}^n A_i$$

- Algunos autores desde (Armour y Buffa 1963) hasta (Gonzalez 2005) hacen una aproximación al problema suponiendo un recinto fijo y lo que es más importante en este punto, que se ajusta completamente a las necesidades del caso en estudio. En esta situación, el 100% de la superficie del recinto está ocupada por alguna de las n actividades que componen el problema, por tanto no existe ninguna holgura.
- Otros autores hacen una aproximación al problema en la que el área del recinto es superior a la suma de áreas de las n actividades. Por tanto existe una cierta holgura, desaprovechando una parte del espacio del dominio.



Figura 3.2.33 Planteamiento con recinto estricto (izq.) y con holgura (dcha.).

En la presente investigación se emplea un planteamiento con recinto estricto, por tanto no tiene sentido emplear ningún indicador que controle el aprovechamiento espacial, aun así, en las referencias se pueden encontrar los siguientes:

Utilización y suficiencia espacial

Una solución con una buena utilización espacial tendrá dos características:

- Un ratio de utilización espacial (RUE) razonable en planta y en volumen, calculado como:

$$RUE = 1 - \text{ratio de espacio libre} \quad (3.36)$$

No es deseable tener un 100% de utilización espacial pues siempre es necesario tener una reserva de espacio para cubrir aspectos relativos al confort y seguridad de los operarios.

- El espacio libre estará concentrado en un área específica o podría ser utilizado para implantar una nueva actividad. Es decir, es preferible que el espacio libre esté concentrado a que esté diseminado.

Así pues, la eficiencia de la utilización espacial puede ser juzgada desde el ratio de espacio libre y desde la distribución de espacios libres. El indicador (ratio de utilización espacial, o RUE) se desarrolla basándose en estos conocimientos y adopta los conceptos del coeficiente k y del coeficiente de forma del indicador de diafanidad para medir la distribución de espacios libres (huecos en la distribución espacial).

1. Si no hay espacios libres:

$$RUE = (1 - |1 - \text{valor objetivo}|) \quad (3.37)$$

2. Si hay una parte libre, los autores proponen:

$$RUE = \left(1 - \left| 1 - \frac{\text{espacio libre}}{\text{area total}} - \text{valor objetivo} \right| \right) \cdot \left(\frac{\text{espacio libre}}{\text{area total}} \right)^2 \cdot (\text{coef. forma})^{\frac{1}{3}} \quad (3.38)$$

3. Si hay más de una parte libre, usar:

$$RUE = \left(1 - \left| 1 - \frac{\text{espacio libre}}{\text{area total}} - \text{valor objetivo} \right| \right) \cdot (\text{ratio } S)^{\frac{1}{2}} \cdot \sum_{n^{\text{espacios}}} \left(\frac{\text{espacio libre}}{\text{area total}} \right)^2 \cdot (\text{coef. forma})^{\frac{1}{3}} \quad (3.39)$$

Las expresiones (3.38) y (3.39) tienen dos partes, cada una de las cuales tiene el siguiente sentido:

- La primera parte de la expresión es el coeficiente de utilización espacial ajustada. El valor objetivo representa la preferencia del coeficiente de utilización espacial definida por el usuario (suele estar entre el 0.8 y 0.9) y define la cantidad de espacio libre que existe en la configuración. Si no hay huecos debería ser 1 (o el valor objetivo) como en (3.37).
- En la segunda parte de la expresión se emplea el ratio S es para medir la concentración de las partes libres. Puede ser igual al ratio de área o igual al ratio k .

Area Utilization Factor (AUF)

(Wang, Hu y Ku 2005) proponen un indicador para medir el índice de ocupación del recinto por las m actividades, denominado AUF_w (*Area Utilization Factor*), que se calcula de la siguiente forma:

$$AUF_{\text{whole}} = \frac{\sum_{i=1}^n A_i}{\sum_{i=1}^n A_i + TBA} \quad (3.40)$$

Donde: TBA es el número de celdas en blanco que existen en la configuración.

Este es un indicador muy sencillo de evaluar y que tiene una aplicación directa si se emplea un modelo geométrico discreto.

Utilización del área productiva (PAU)

El nivel de ocupación del espacio habitualmente solo se evalúa en términos de área libre disponible. Sin embargo, (Raman, Nagalingam y Lin 2009) emplean 2 medidas para calcularla (el ratio de área libre y la distribución de áreas libres). Estas dos medidas pueden llevar a la conclusión errónea de que cuanto mayor sea el área empleada, mejor será la efectividad de uso del área, algo que realmente no es así, pues deben tenerse en cuenta también si las áreas ocupadas son efectivas o no lo son.

3.3 RELACIÓN OBJETIVOS-PRINCIPIOS-INDICADORES

Una vez descritos los indicadores encontrados en la bibliografía, y propuesto uno nuevo como es la circulación en pasillos, resta por realizar un resumen de que objetivos y que indicadores se pueden asociar a cada uno de los 6 principios básicos de una correcta distribución en planta de los establecimientos industriales fijados en el trabajo de referencia de Muther.

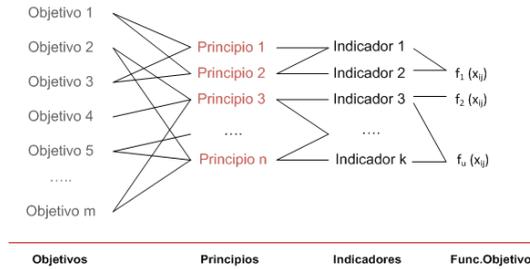


Figura 3.3.1 Relación Objetivos-Principios-Indicadores.

Cabe recordar que la presente investigación se enmarca dentro de la aproximación al problema desde el punto de vista del layout de bloques, siendo en esta fase de resolución del problema imposible localizar algunos elementos de la distribución final, como pueden ser la localización de los puntos de entrada y salida de material de cada actividad o la posición y anchura de los pasillos, por tanto, algunos indicadores de los enunciados en el apartado anterior no son de aplicación directa.

A continuación se enumeran los principios, los objetivos asociados a estos (en color gris y enumerados según la clasificación de Muther) y los indicadores (en el caso de que existan) relacionados directamente con ellos para, en apartados posteriores, realizar la selección de aquellos que se considerarán en la fase de optimización.

a) Principio de integración de conjunto

“La mejor solución será aquella que integre a los operarios, materiales, maquinaria y cualquier otro factor, de modo que el compromiso entre todos ellos resulte mayor”

7. Mayor uso de la maquinaria, mano de obra y los servicios.

9. Reducir el trabajo indirecto en general.

10. Lograr una supervisión fácil.

El enunciado del principio no hace más que poner de manifiesto el claro carácter multiobjetivo del problema que se está resolviendo.

No hay un único indicador que pueda condensar este principio, sino que más bien sería un grupo de indicadores, que recogieran plenamente el concepto de integración de conjunto expresado en este principio.

b) Principio de la mínima distancia recorrida

“En igualdad de condiciones, la mejor solución será aquella que permita al material desplazarse la mínima distancia posible”

3. Incrementar la producción.

4. Disminuir los retrasos en la producción.

6. Reducir el manejo de materiales.

8. Reducir el material en proceso y el tiempo de fabricación.

Este es el principio que tiene una serie de indicadores que recogen claramente el sentido que Muther quiso transmitir al enunciarlo. Es el principio de mayor importancia de todos, pues una menor distancia recorrida devenga en unos menores costes de producción. Los indicadores que se pueden asociar con este principio se muestran en la siguiente lista:

- *MHC - Material Handling Cost (Coste entre centros, Coste EDIST).*
- *MMT - Material Movement Time.*
- *Índice de cercanía (cualitativo).*
- *Adyacencia (cualitativo).*

c) Principio de la circulación

“En igualdad de condiciones, la mejor solución será aquella 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”

3. Incrementar la producción.

4. Disminuir los retrasos en la producción.

6. Reducir el manejo de materiales.

8. Reducir el material en proceso y el tiempo de fabricación.

11. Disminuir la congestión y confusión.

12. Disminuir el riesgo para el material o su calidad.

Esto, en 2D, es complejo de conseguir al no ser la secuencia lineal y tener, cada actividad, más de dos anexas. Algunos indicadores, como el MHC pueden asociarse a este principio, pero sin duda, el indicador propuesto es el que mejor se ajusta a este principio.

- *Circulación*

d) Principio del espacio cúbico

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

5. Ahorrar espacios.

Este principio se cumple estrictamente si se emplea un modelo geométrico de más de 2D, pues se aprovecha el espacio en las tres dimensiones. Sin embargo, según sea el problema a abordar, es posible que los costes de establecer el proceso en más de dos dimensiones sean excesivos, en cuyo caso se opte por un modelo geométrico de 2D. En estos casos, el principio no se cumplirá al 100% si el tamaño del recinto es mayor que el estrictamente necesario (el de la suma de las áreas de las actividades). Los indicadores que cuantifican el cumplimiento del principio son los de aprovechamiento del área:

- *RUE (utilización y suficiencia espacial).*
- *AUF (factor de utilización del área).*
- *PAU (utilización del área productiva).*

Si se emplea un recinto de área estricta, y un modelo geométrico discreto, es posible que el constructor genere zonas destinadas a las actividades muy poco compactas, haciendo que la implantación sea complicada.

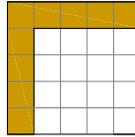


Figura 3.3.2 Actividad con posible problema de implantación.

En estos casos, se debe emplear algún indicador que mejore la falta de compactidad de las actividades, para evitar los problemas de implantación. Los que se muestran más efectivos a la hora de controlar este problema son:

- *Forma.*
- *Indicador de perímetro Ω .*
- *Compactidad.*
- *Forma Media Ponderada.*
- *SRF.*
- *Compactidad Media Ponderada.*

e) Principio de satisfacción y seguridad

“En igualdad de condiciones, la mejor solución será aquella que haga el trabajo más satisfactorio y seguro para los operarios, los materiales y la maquinaria”

1. Reducir los riesgos para la salud y aumentar la seguridad de los operarios.

2. Elevar la moral y la satisfacción del trabajador.

En el enunciado del principio se remarca que el trabajo sea satisfactorio, pero seguro para los trabajadores. El concepto de seguridad es difícil de evaluar cuantitativamente, por tanto el único indicador que se encuentra en la bibliografía es:

- *Movimientos peligrosos (cualitativo).*

f) Principio de flexibilidad

“En igualdad de condiciones, será más efectiva la solución que pueda ser ajustada o reordenada con menos costos o inconvenientes”

13. Aumentar la facilidad de ajuste a los cambios de condiciones.

La flexibilidad de una planta es un concepto que ha sido discutido por diversos autores tal y como se comentó en puntos anteriores, siendo un concepto difícil de cuantificar, pues deberían plantearse diversos escenarios sobre una misma configuración, algo que no es habitual en los problemas de optimización consultados. Sin embargo algunos autores plantean indicadores basados en distintos conceptos cuantitativos o simplemente cualitativos:

- *FLF* (Raman, Nagalingam y Lin 2009).
- *Flexibilidad (cualitativo)*.

Por otra parte, en el caso de modelos geométricos 2D discretos, un aspecto que mejora la flexibilidad es conseguir formas de las actividades lo más cuadradas posibles, pues así se podrían intercambiar posiciones con otras del mismo área. Desde este punto de vista, los indicadores serían los mismos que el principio d).

- *Forma*.
- *Indicador de perímetro Ω* .
- *Compacidad*.
- *Forma Media Ponderada*.
- *SRF*.
- *Compacidad Media Ponderada*.

3.4 SELECCIÓN DE LOS INDICADORES A EMPLEAR

Una vez descritos todos los indicadores que se han empleado en el problema de distribución en planta en la bibliografía, y propuesto uno nuevo que mide el flujo en los pasillos de material, se plantea la necesidad de tomar decisiones acerca de cuáles de los indicadores cuantitativos expuestos son significativos, suficientes e independientes entre sí. El objetivo de esta fase del estudio es obtener una lista de indicadores cuantificables, con los que trabajar en la fase experimental de optimización.

Los indicadores cualitativos no se consideran porque tal y como también se comentó en apartados anteriores, en el planteamiento que se ha hecho del problema únicamente se consideran los datos cuantitativos para evitar problemas de subjetividad en el proceso de optimización. Por tanto el estudio que se realiza a lo largo de este trabajo comprende únicamente a los indicadores cuantitativos del problema de distribución en planta.

A continuación se revisan los indicadores expuestos por categorías, comprobando la independencia de cada uno de ellos respecto al resto y si fuera necesario eliminando aquellos que resulten redundantes o que no aporten información útil al problema.

Para conocer la relación entre dos indicadores no se puede estudiar únicamente la formulación matemática de los mismos, al menos cuando intervenga un indicador de actividad, ya que es posible que cada uno de los indicadores alcance su peor valor para diferentes actividades de una misma configuración. En esta situación, se necesita una herramienta para determinar la independencia de los indicadores.

Para obtener datos de las relaciones existentes entre todos estos parámetros se realiza un paseo aleatorio (*random walk*) generando 25000 soluciones independientes entre sí del problema de 20 actividades de (Armour y Buffa 1963) sobre un recinto fijo sin holguras, obteniendo los valores de los indicadores más significativos para comprobar su independencia dos a dos. El constructor de soluciones emplea un modelo geométrico discreto y un relleno mediante curvas de relleno (SFC) cuya mecánica de colocación se comenta en detalle en el apartado 6.1.2.

Se emplea el paseo aleatorio como una técnica de estudio de soluciones, que permitirá determinar que variables de estudio son significativas para centrar la investigación en ellas. Los datos obtenidos en este paseo aleatorio para el indicador de coste de transporte de materiales (MHC) obtenido con una métrica rectilínea son los mostrados en la Figura 3.4.1.

Del paseo aleatorio se obtienen los siguientes datos estadísticos para la formulación establecida del problema de distribución en planta y los indicadores de actividad y configuración más significativos.

| | Coste CTC | γ min | ρ min | φ min | Ω^4 max | k min | Ω^{-1} min | δ max |
|-----------------|-----------|--------------|------------|---------------|----------------|-------|-------------------|--------------|
| Mínimo ó Máximo | 7714,34 | 0,75 | 0,50 | 0,36 | 3,01 | 0,36 | 0,81 | 1,00 |
| Promedio | 12224,85 | 0,48 | 0,17 | 0,13 | 9,81 | 0,13 | 0,57 | 1,07 |
| Mediana | 12207,17 | 0,48 | 0,15 | 0,14 | 8,51 | 0,14 | 0,58 | 1,08 |

Tabla 3.4.1 Datos estadísticos de indicadores obtenidos mediante Paseo Aleatorio (1).

| | CosteEDIST | Circul | FMP | SRF | CMPo | RMPo | IMPo | kMPo |
|-----------------|------------|--------|------|------|------|------|------|------|
| Mínimo ó Máximo | 9068,55 | 0,00 | 0,65 | 1,09 | 0,94 | 0,81 | 2,40 | 0,65 |
| Promedio | 12993,36 | 0,33 | 0,36 | 1,30 | 0,79 | 0,46 | 4,54 | 0,36 |
| Mediana | 12961,08 | 0,33 | 0,36 | 1,26 | 0,78 | 0,46 | 4,06 | 0,36 |

Tabla 3.4.2 Datos estadísticos de indicadores obtenidos mediante Paseo Aleatorio (2).

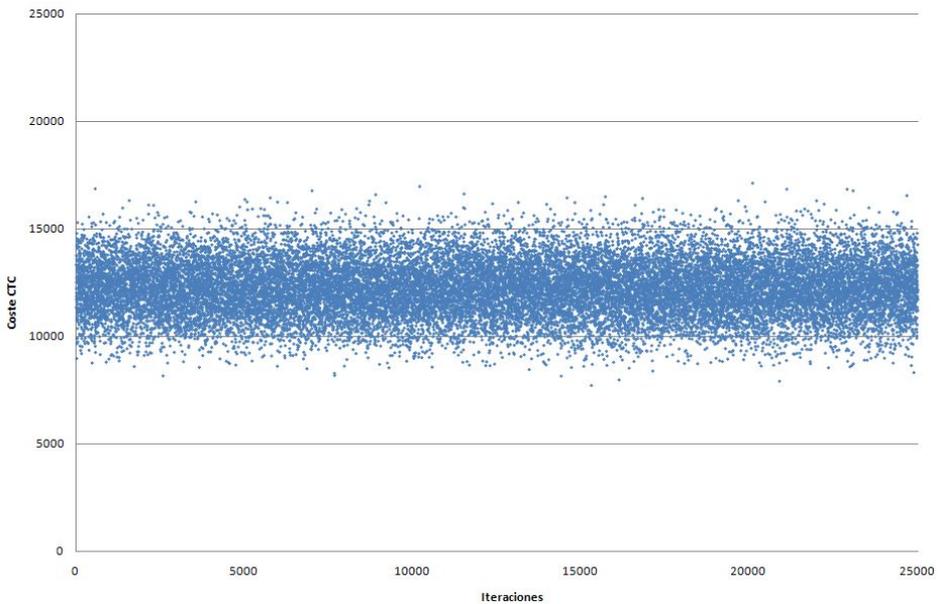


Figura 3.4.1 Representación del paseo aleatorio Coste-Nº Iteración.

Se estudian los indicadores cuantitativos por tipos, seleccionando el que se considera más adecuado para la investigación.

Como criterio a la hora de decidir si dos indicadores son concordantes o discordantes se emplea, por una parte el aspecto de la nube de puntos obtenida en el paseo aleatorio y por otra el número de puntos que configuran la frontera de Pareto de cada uno de los bicriterios. Una frontera de Pareto con pocos puntos implica que los indicadores son concordantes (tal y como se puede observar en la Figura 3.4.3) y si tiene muchos puntos implica discordancia entre los indicadores (como ocurre en la Figura 3.4.2).

3.4.1 Indicadores de flujo

De los indicadores de flujo comentados en puntos anteriores se decide emplear en la investigación dos, como son el coste entre centroides (**CTC**) y el indicador propuesto de **Circulación**. Pese a que los dos indicadores son de flujo, se puede observar en la Figura 3.4.2 que no son concordantes, pues no existe una correlación directa entre los valores de uno y otro.

La nube de puntos formada por las soluciones es difusa y tiene forma circular, y la frontera de Pareto de los dos criterios tiene 10 puntos lo cual da muestra de la no concordancia de los dos indicadores.

La frontera de Pareto (que será definida en apartados posteriores), recoge todas aquellas soluciones que dominan a otras y que, a su vez, no son dominadas por ninguna. Una solución domina a otra cuando los valores de ambos objetivos son más cercanos al óptimo. En las siguientes figuras, la frontera la conforman todos los puntos grafiados en rojo.

Una frontera con muchos puntos da muestra de la dispersión de valores y de la no concordancia de los criterios estudiados, siendo este el criterio empleado para descartar el empleo de alguno indicadores que pueden resultar redundantes.

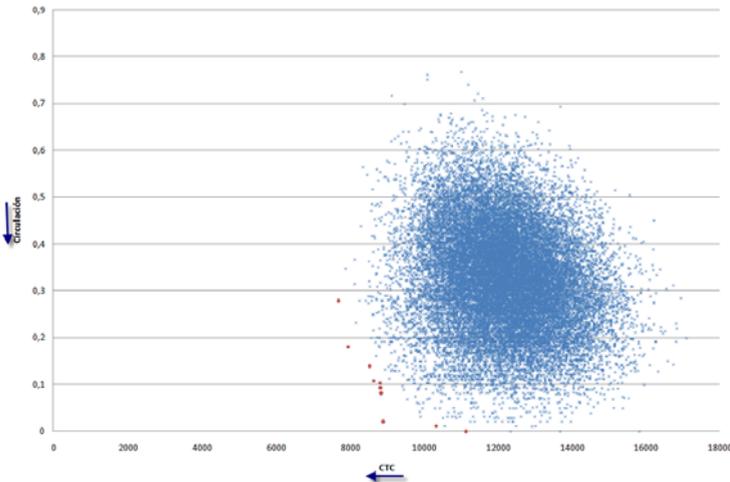


Figura 3.4.2 Relación Coste entre centroides - circulación.

No se considera en la investigación *el tiempo de movimiento de los materiales* pues ninguno de los problemas de test de la bibliografía da valores para poder implementarlo en los modelos. Tampoco se considerará el conjunto de indicadores de Lin, pues la formulación requiere datos que no se establecen en el problema de Armour y Buffa.

Tampoco se considera la distancia EDIST, que pese a controlar la forma de las actividades y evitar algunas aberraciones, no aporta valores diferentes a los de la distancia entre centros, con la que guarda una fuerte correlación, tal y como se puede observar en la Figura 3.4.3. Los datos tienen una baja dispersión y la frontera tiene únicamente 2 puntos (marcados en rojo en la imagen).

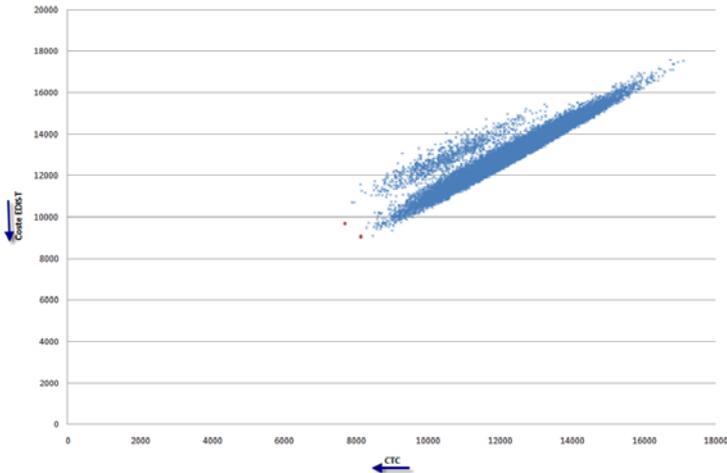


Figura 3.4.3 Relación Coste entre centroides - Coste EDIST.

3.4.2 Indicadores geométricos

Los indicadores geométricos proporcionan información acerca de la forma y distribución de las actividades y en general de la configuración. Tal y como se ha comentado en el apartado anterior, entre estos indicadores se pueden encontrar de configuración, que tienen en cuenta los indicadores locales de cada una de las n actividades y dan un valor (generalmente de promedio) del conjunto de actividades. Y por otra parte, una serie de indicadores de actividad, que para ser empleados en la optimización de la distribución en planta se centran en la mejora del peor de los valores de las n actividades, de esta manera, se mejorarán todos los demás de una manera indirecta.

En la Tabla 3.4.3 se resumen los diferentes indicadores geométricos expuestos en el punto anterior, encuadrándolos en cada uno de estos dos grupos.

| Tipo | Indicador |
|---------------|---|
| ACTIVIDAD | $\Omega^1, \gamma, \rho, k, \Omega_4, \varphi$ |
| CONFIGURACIÓN | $SRF_w, \gamma_{MP}, \rho_{MP}, k_{MP}, \Omega_{4MP}, \varphi_{MP}$ |

Tabla 3.4.3 Indicadores cuantitativos recopilados de la bibliografía.

En primer lugar se realizan los descartes de aquellos indicadores que tienen una concordancia más acusada y que, por tanto, no son de interés por ser redundantes.

Se descarta la utilización del indicador de forma k , que está muy relacionado con el indicador de Forma (tal y como se puede ver en la Figura 3.4.4), su frontera está compuesta por un único punto.

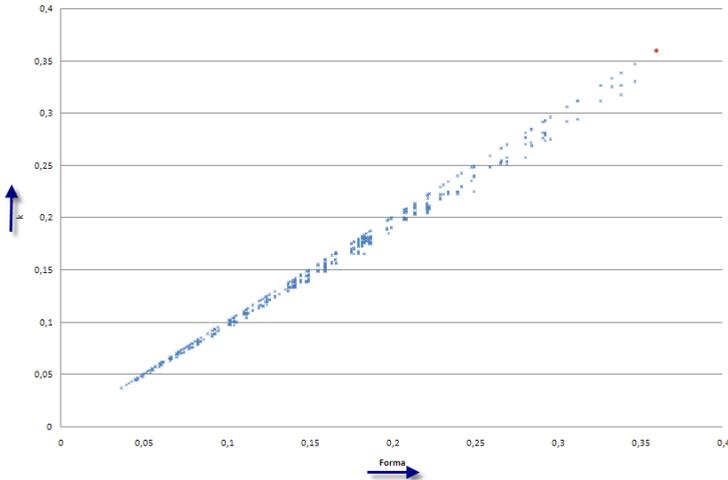


Figura 3.4.4 Correlación del indicador de Forma y el factor k .

Los indicadores de configuración ρ MP (Robustez media ponderada) y k MP (k media ponderada) son concordantes con la Forma Media Ponderada, tal y como ponen de manifiesto las gráficas de la Figura 3.4.5. En las mismas se observa la poca dispersión de los valores entorno a una recta y los puntos que conforman la frontera (1 y 2 puntos respectivamente).

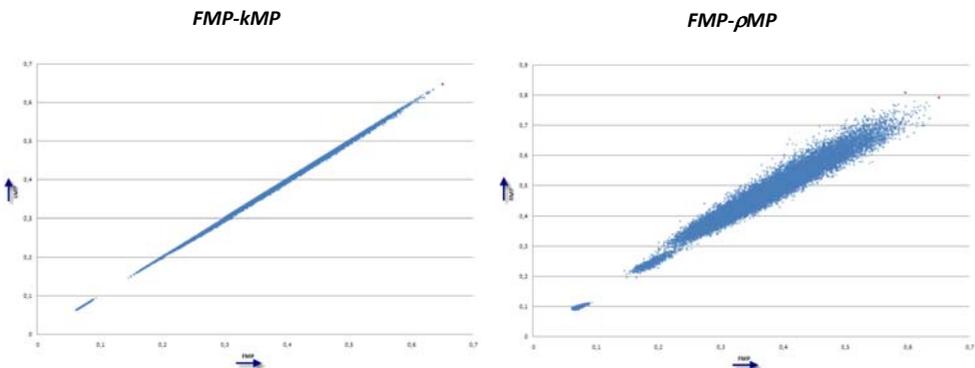


Figura 3.4.5 Correlación de la FMP con la k MP y la ρ MP.

Se puede establecer también la concordancia del indicador de Inercia con la Inercia Media Ponderada (IMP) y con el indicador de perímetro (Ω). En la Figura 3.4.6 se observa que pese a que la dispersión es mayor que en los casos anteriores y que no se puede establecer una relación lineal entre indicadores, los valores son dominados por un solo punto.

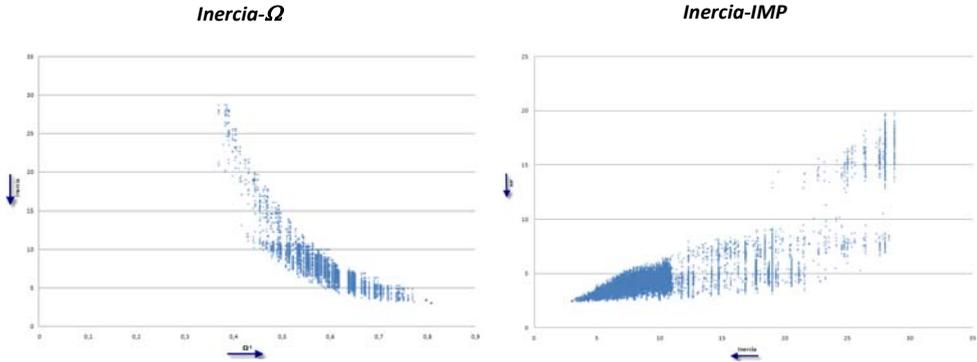


Figura 3.4.6 Correlación de la Inercia con la IMP y con Ω^{-1} .

Una vez eliminados los indicadores con una mayor concordancia, se enfrentaron entre sí los restantes para tratar de encontrar similitudes entre ellos, y reducir el número de valores a emplear en la fase de optimización posterior.

En primer lugar se enfrentan los indicadores de compacidad y la compacidad media ponderada, dando como resultado la Figura 3.4.7. En la misma se observa que la frontera de Pareto queda definida por un solo punto, por tanto se puede considerar que son dos indicadores redundantes y bastará con considerar únicamente el de compacidad.

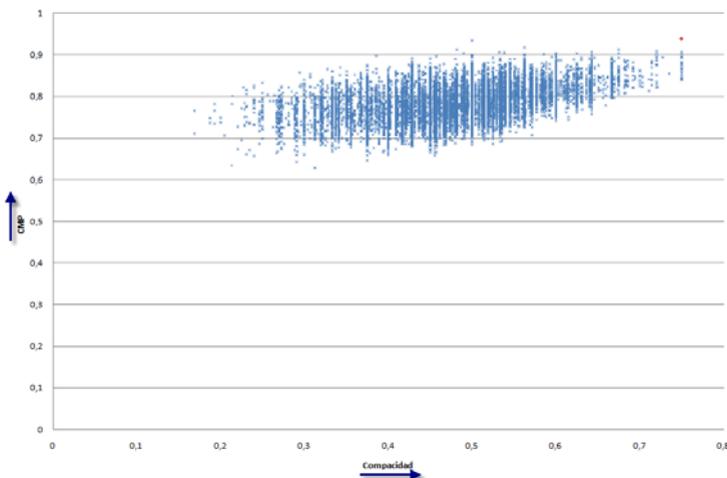


Figura 3.4.7 Correlación de la CMP con la compacidad.

Si se representa el comportamiento de la CMP y la compacidad con el resto de indicadores, se puede observar que la forma obtenida en todos los casos es muy similar aunque la compacidad tiene una mayor amplitud y diversidad de valores, por tanto se empleará el indicador de compacidad y no el de CMP, sirva como ejemplo los mostrados en la siguiente figura.

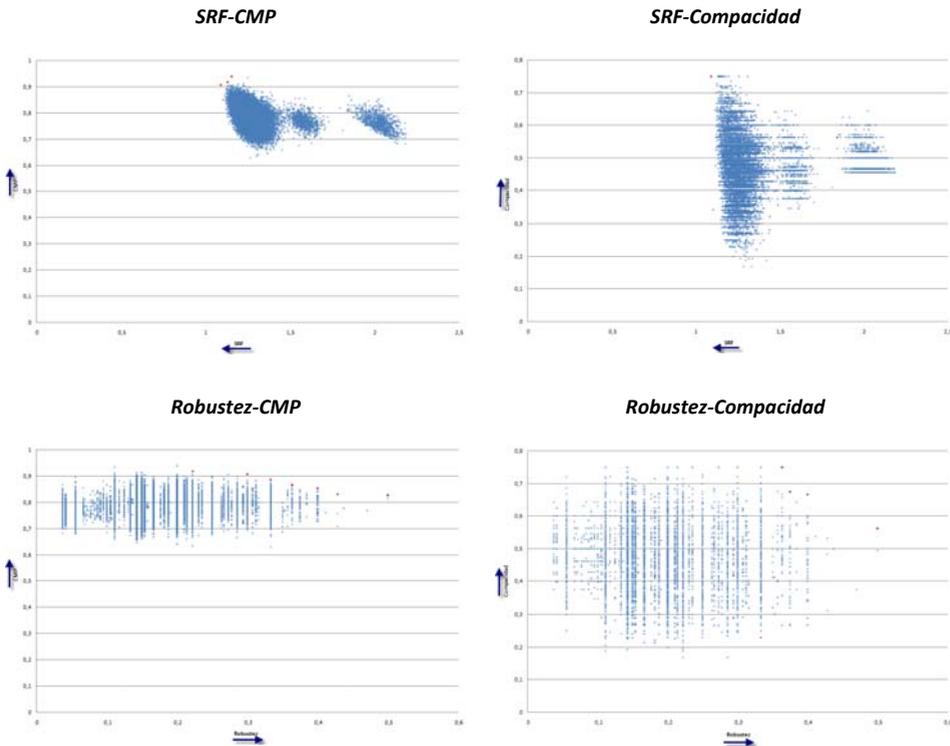


Figura 3.4.8 Relación de CMP y Compacidad con la robustez (ab) y SRF (ar).

Por tanto, la lista reducida de indicadores geométricos, una vez eliminados los que tienen una mayor concordancia es la mostrada en la Tabla 3.4.4.

| Tipo | Indicador |
|---------------|--------------------------------|
| ACTIVIDAD | $\gamma, \rho, \Omega_4, \Phi$ |
| CONFIGURACIÓN | SRF_w, Φ_{MP} |

Tabla 3.4.4 Indicadores geométricos reducidos.

El resto de indicadores no tiene una correlación directa clara, y por tanto no se puede considerar que sean redundantes. A continuación se muestran algunas de las relaciones entre indicadores, que se emplearán para determinar cuáles son los que se emplean en fases posteriores.

3.4.2.1 Indicador de perímetro

Se estudia la relación del indicador global de perímetro, SRF frente al resto de indicadores, pudiéndose concluir que respecto a los objetivos de Forma Media Ponderada, forma, compacidad y robustez tiene un comportamiento similar, obteniéndose curvas del estilo de las mostradas en la parte superior de la Figura 3.4.9. En todas ellas, la frontera de Pareto queda conformada por 4 puntos, y se puede considerar que los indicadores no son congruentes.

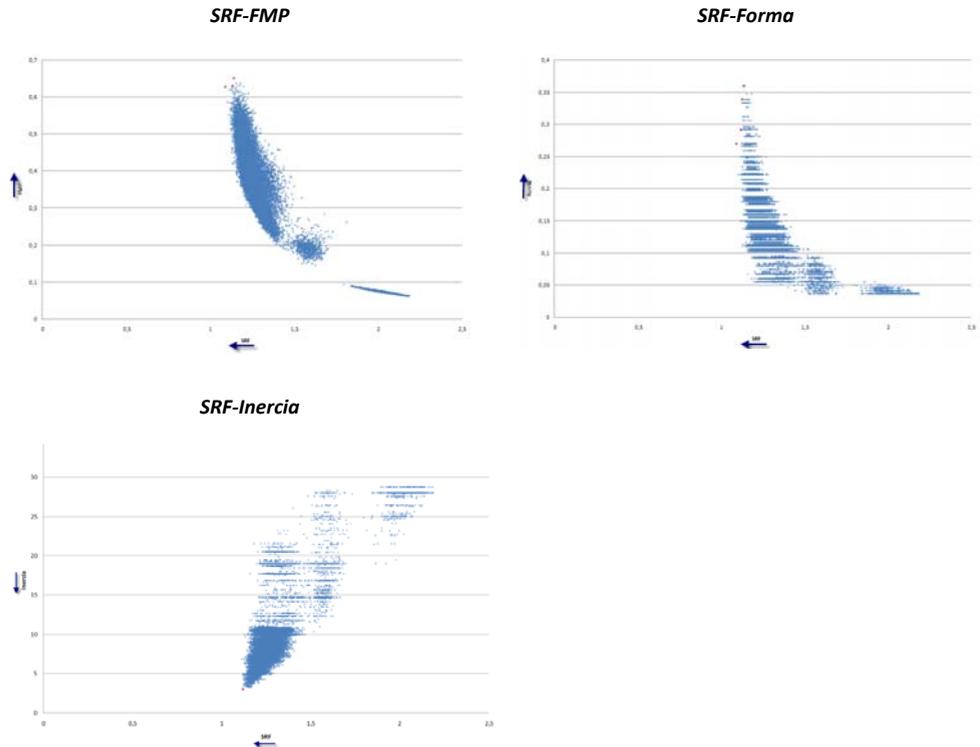


Figura 3.4.9 Representación de SRF frente a la forma media ponderada y Forma (arr) e Inercia (ab).

El comportamiento del indicador respecto a la inercia es diferente, pues como se observa en la parte inferior de la Figura 3.4.9 todas las soluciones están dominadas por un solo punto y la nube de puntos tiene forma de cuña, mostrando la misma una cierta congruencia entre los indicadores.

3.4.2.2 Indicador de robustez

En la Figura 3.4.10 se muestra la relación entre el indicador de robustez y el resto de indicadores. Cabe destacar la gran independencia del par de indicadores Robustez-Compacidad (con 4 puntos de Frontera y una gran dispersión de los valores) y la tendencia a una relación exponencial entre los indicadores Robustez-Inercia (pese a que la frontera queda definida también por cuatro puntos).

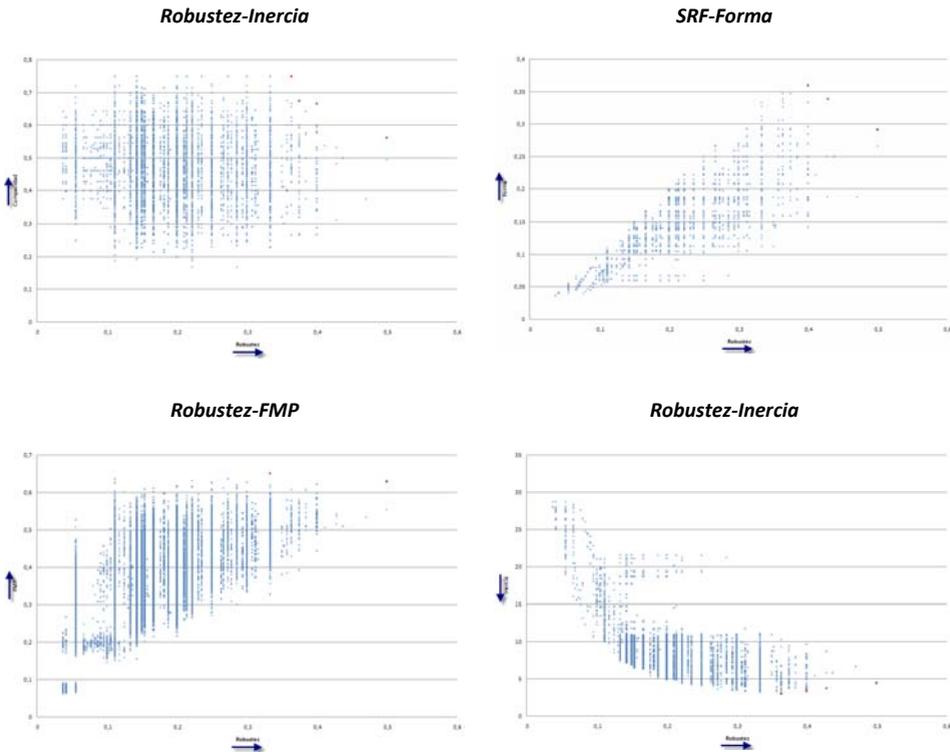


Figura 3.4.10 Representación de la robustez frente al resto de indicadores.

3.4.2.3 Indicador de compacidad

Tal y como se muestra en la Figura 3.4.11, el indicador de compacidad es independiente de los de Forma, FMP e Inercia (en todos los casos existe una gran dispersión de valores y la frontera queda definida por, al menos cuatro puntos).

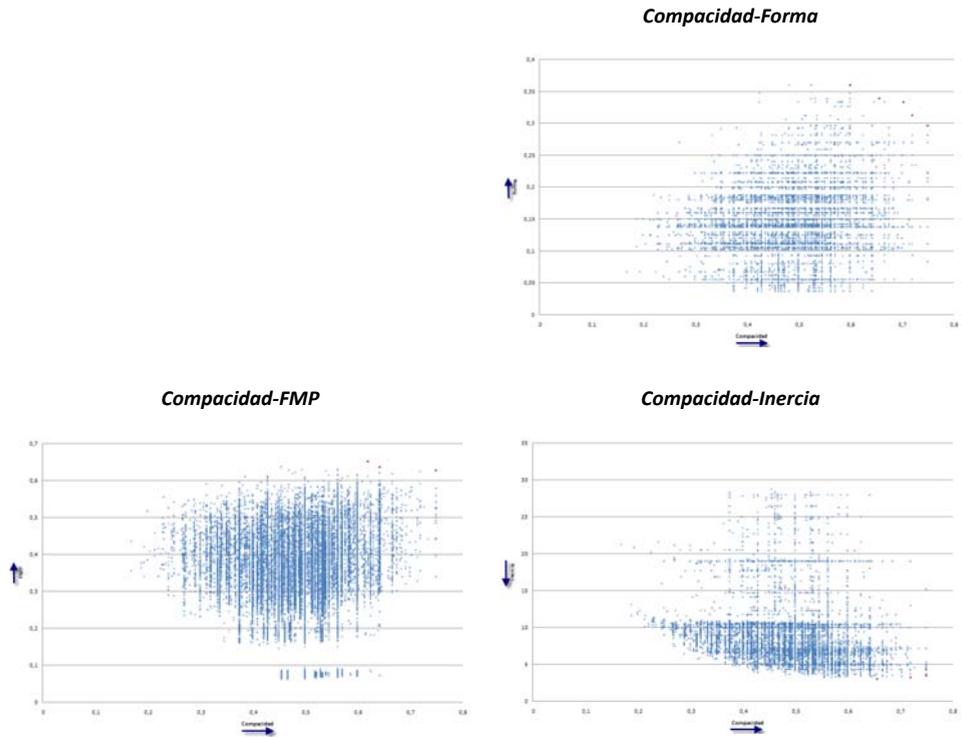


Figura 3.4.11 Representación de la compacidad frente al resto de indicadores.

3.4.2.4 Indicadores de forma

Solo resta enfrentar los valores obtenidos para los indicadores de forma, tanto el de actividad como el de configuración (FMP). En la Figura 3.4.12 se puede observar la relación del indicador de actividad con el de configuración (centro) y que muestra que en absoluto tienen una correlación directa. También se puede observar que inercia y forma tienen una relación que se puede asimilar a una función exponencial, tal y como ocurría con la robustez.

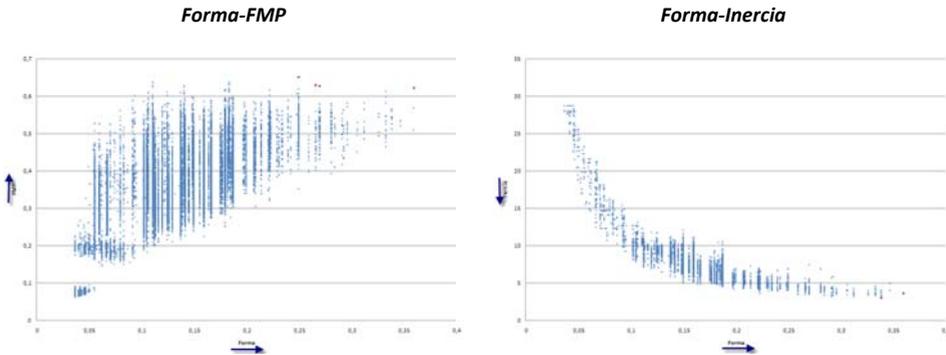


Figura 3.4.12 Representación del indicador de forma frente al resto de indicadores.

Por último se representan los valores del paseo aleatorio obtenidos para los indicadores de Forma Media Ponderada y el de inercia. Como se puede observar, no se detecta una correlación directa de ambos indicadores, por la forma de la nube de puntos obtenida.

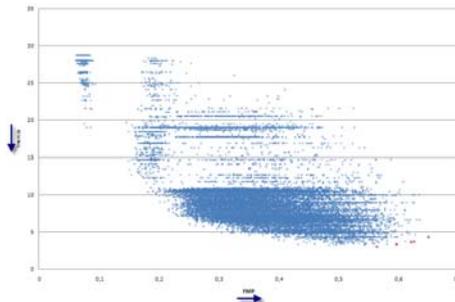


Figura 3.4.13 Representación de la Forma Media Ponderada frente a la inercia.

3.4.2.5 Relación con el indicador propuesto

Solo resta comprobar si alguno de de los indicadores geométricos que se van a emplear tiene alguna correlación directa con el indicador de flujo propuesto, con la circulación. En la Figura 3.4.14 se pueden observar las gráficas de relación obtenidas en el paseo aleatorio.

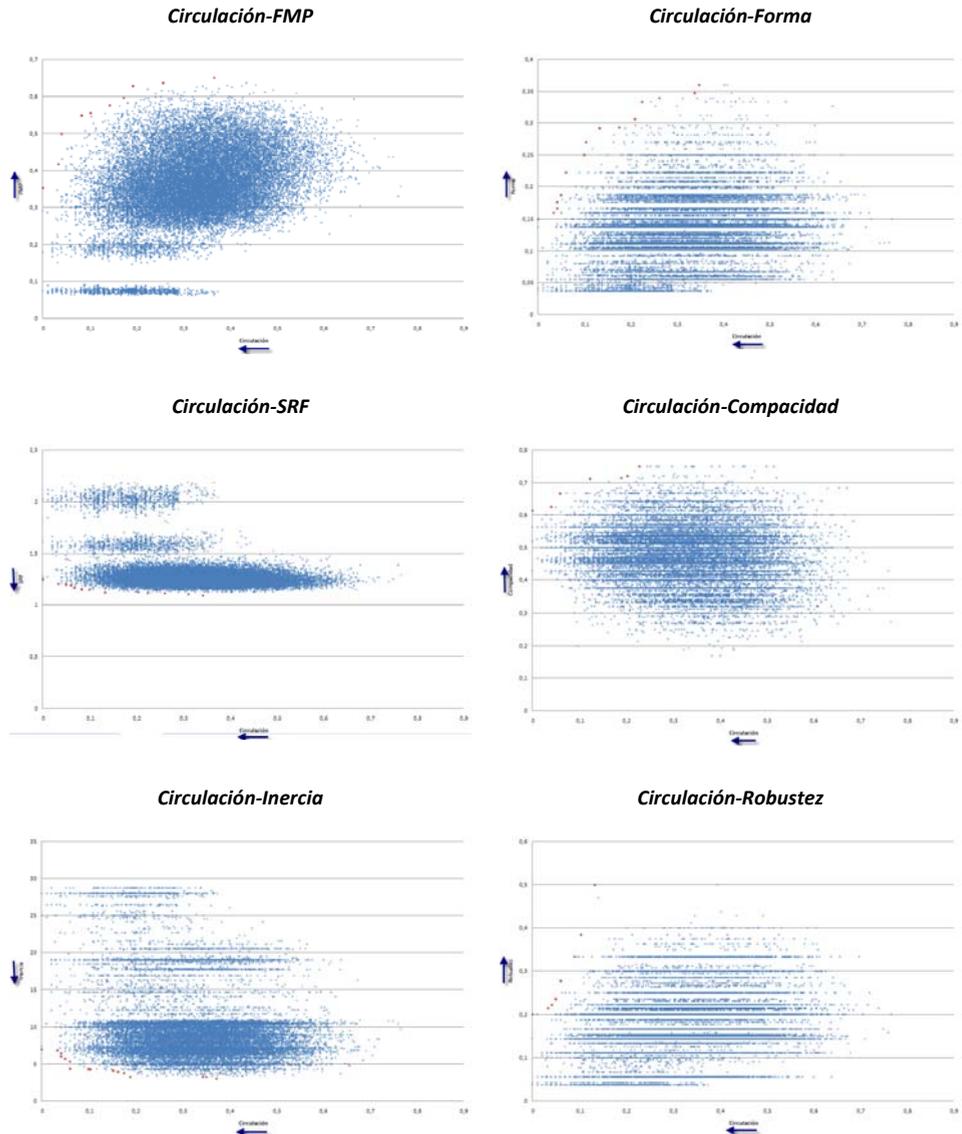


Figura 3.4.14 El indicador de circulación frente al resto de los indicadores geométricos.

En las figuras anteriores se puede apreciar que el indicador de circulación es discordante con los indicadores geométricos estudiados. En todas, se puede observar que los valores obtenidos tienen una gran dispersión y prueba de ello es el elevado número de puntos que conforman las fronteras de Pareto (nunca inferior a 7, y con un promedio de 11).

Respecto al indicador de perímetro global, el SRF, se produce una cierta estratificación de la relación, diferenciándose varios grupos de soluciones, pues se pueden observar hasta tres bandas horizontales entorno a valores de SRF de 1.2, 1.6 y 2.1. Algo similar, aunque menos acusado ocurre con el indicador de inercia.

La figura también muestra claramente que no hay una dependencia lineal entre circulación y compacidad aunque la nube de valores adopta una cierta forma elíptica, al igual que ocurre con la Forma Media Ponderada.

Como también se puede observar en las imágenes anteriores, la relación de la circulación con la robustez y la forma mínima es muy similar. En ambos casos, se ve que no existe ninguna relación entre indicadores y los datos se encuentran muy dispersos en todo el gráfico.

3.4.3 Indicadores seleccionados

A partir de todo lo comentado en los apartados anteriores se decide continuar la investigación empleando los indicadores mostrados en la Figura 3.4.15 como objetivos de la fase de optimización.

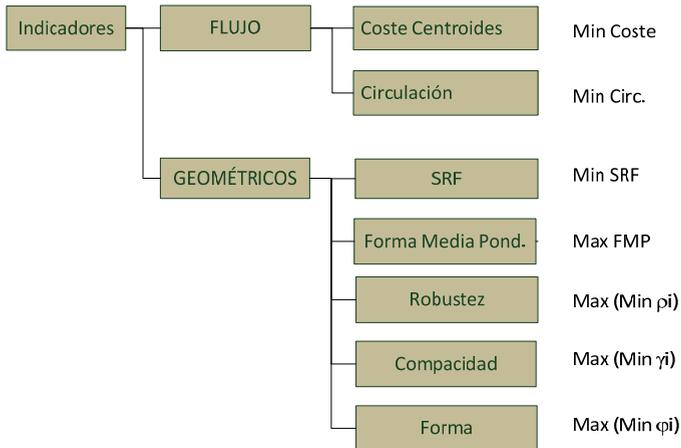


Figura 3.4.15 Indicadores seleccionados para la optimización.

Indicadores de flujo

Se empleará el indicador de **coste entre centroides**, puesto que en todas las referencias se utiliza como objetivo principal de la optimización, independientemente de que la misma sea mono o multiobjetivo. El coste EDIST pese a que es eficaz para controlar algunas incorrecciones formales en la construcción de la solución, no se considera, pues el resto de indicadores geométricos ya van a controlar la forma en la que las actividades se implantan en la solución, por tanto no tiene sentido emplearla en el proceso de optimización. Este indicador se relaciona directamente con el *principio de mínima distancia recorrida* que formuló Muther.

También se utilizará y explorarán las posibilidades del indicador de **circulación**, que ha sido propuesto en esta tesis. Tal y como se ha mostrado en apartados anteriores, es independiente de todos los indicadores geométricos, por tanto puede resultar muy útil como complemento del coste entre centroides en la fase de layout de bloques. Este indicador refleja claramente lo establecido por Muther en el *principio de mínima circulación*.

Indicadores geométricos

El segundo grupo de indicadores, los geométricos, se relacionan directamente con el *principio del espacio cúbico* y el *principio de flexibilidad*, tal y como se comentó en apartados anteriores.

Entre los indicadores geométricos de configuración se decide emplear uno que considera el perímetro de las actividades, el **SRF** propuesto por Wang y otro que considera la **Forma Media Ponderada** de la configuración. Estos dos indicadores proporcionan a la optimización un control formal de la solución, dándole mayor importancia a la calidad formal de las actividades de mayor tamaño, por ello se considera interesante emplear en la optimización también una serie de indicadores geométricos de actividad, que pueden ayudar a controlar los problemas de forma de las actividades de menor tamaño.

Se considerarán también en la fase de optimización los indicadores de: **compacidad** (que vela por conseguir que las actividades se coloquen sobre el recinto discreto de la forma más compacta posible), **robustez** (persigue conseguir formas cuadradas de las actividades, para aumentar su flexibilidad) y **forma** (que busca mejorar los dos indicadores anteriores de forma conjunta).

Los indicadores de actividad y configuración seleccionados, aunque persiguen objetivos comunes, no proporcionan valores iguales, por tanto se considera que deben ser utilizados en la fase de optimización.

4 MÉTODOS DE OPTIMIZACIÓN MULTIOBJETIVO

A partir del trabajo pionero que Rosenberg realizara a fines de los años 60 con respecto a la posibilidad de usar búsqueda genética como una forma de lidiar con objetivos múltiples, esta nueva área de investigación (llamada ahora optimización evolutiva con objetivos múltiples) ha crecido considerablemente y esto se refleja con un notable incremento (sobre todo en los últimos 15 años) de artículos técnicos en revistas internacionales, y en otros foros científicos. La optimización con objetivos múltiples es, sin duda, un área de investigación muy importante tanto, debido a que la mayoría de los problemas del mundo real tienen objetivos múltiples. De hecho, no hay ni siquiera una definición de "óptimo" que sea aceptada universalmente, como en el caso de la optimización con un solo objetivo. Es por ello que no resulta fácil cuando se quiere comparar los resultados de una técnica con los de otra, porque normalmente la decisión acerca de cuál es la mejor respuesta la resulta hacer el diseñador (los cuales suelen ser normalmente subjetivos).

La idea más simple para tener un problema con varios objetivos sería combinarlos en uno solo usando una suma, una multiplicación o cualquier otra combinación de operaciones aritméticas. Hay, sin embargo, problemas obvios con esta técnica. El primero de ellos es que se debe disponer de información escalar precisa sobre el rango de los objetivos, a fin de evitar que uno de ellos domine a los demás. Esto implica saber, en la medida de lo posible, el comportamiento de cada una de las funciones objetivo, lo cual es normalmente (al menos en la mayoría de las aplicaciones del mundo real) un proceso muy costoso (en términos de tiempo de CPU). Si esta combinación de objetivos es posible (y lo es, en algunos casos), esta técnica no sólo es la más simple de implementar, sino que además es la más eficiente. Al proceso de combinar objetivos en una sola función se le denomina normalmente función agregada, y se le ha utilizado en diversas ocasiones con éxito relativo en problemas en los cuales el comportamiento de las funciones objetivo se conoce más o menos bien.

En el proceso de seleccionar las funciones objetivos para resolver el problema de la distribución en planta, parte de los objetivos y principios que rigen la resolución de este tipo de problemas, autores como (Muther 1968) y (Moore 1971) entre otros, presentan una relación de los objetivos perseguidos, que se resumen en la ordenación de las áreas de trabajo y equipo que sea más económica, al mismo tiempo más segura y satisfactoria para los empleados. De esta forma los criterios tomados en cuenta en la optimización multiobjetivo (multicriterio) se basa en una "combinación" de los objetivos planteados por estos autores. En la bibliografía existente se pueden encontrar diferentes formulaciones que abordan el tratamiento conjunto de los mismos optimizándolos simultáneamente. Existen formulaciones del tipo cualitativo, cuantitativo o una combinación de ambas. Los criterios cuantitativos utilizados en las formulaciones han sido principalmente: minimizar el coste de mantenimiento, maximizar los índices geométricos como compacidad, robustez, forma y maximizar la utilización del espacio. Los criterios cualitativos se basan en los índices de cercanía numéricos, la flexibilidad, la seguridad y el confort entre otros.

4.1 OPTIMIZACIÓN MULTIOBJETIVO

Los problemas reales de ingeniería, generalmente no se pueden condensar en la optimización de una sola función objetivo, por tanto es necesario fijar un marco de trabajo para estas situaciones. Cualquier problema de optimización multiobjetivo (también llamado optimización multicriterio, multidesarrollo u optimización vectorial) se formula de manera general como:

Encontrar el vector $\bar{x} = (x_1, x_2, \dots, x_n)^T$ que optimice el conjunto de funciones objetivo $[f_1(\bar{x}), f_2(\bar{x}), \dots, f_m(\bar{x})]$, satisfaciendo el conjunto de restricciones:

$$g_i(\bar{x}) \leq 0 \quad i = 1, 2, \dots, u \quad (4.1)$$

$$h_i(\bar{x}) = 0 \quad i = 1, 2, \dots, p \quad (4.2)$$

Donde: m es el número de funciones objetivo.
 n es el número de variables de decisión del problema.
 u es el número de restricciones de desigualdad.
 p es el número de restricciones de igualdad.

Óptimo de Pareto

Es prácticamente imposible, y más en problemas de cierta entidad, que pueda existir un solo vector \bar{x} que optimice simultáneamente todos los objetivos. La noción más cercana al concepto monobjetivo de "óptimo" fue originalmente propuesta por Francis Ysidro Edgeworth en 1881 y generalizada posteriormente por Wilfredo Pareto en 1896.

En términos de minimización de objetivos, se dice que un vector $\bar{x} \in S$ es **óptimo de Pareto** si no existe otro $\bar{x} \in S$ tal que $f_i(\bar{x}) \geq f_i(\bar{x})$ para toda $i=1, \dots, m$ y $f_j(\bar{x}) > f_j(\bar{x})$ para cualquier j .

Donde S es el conjunto de soluciones factibles. Expresado de otra forma, se puede decir que:

\bar{x} es un **óptimo de Pareto** si no existe un vector factible de variables de decisión $\bar{x} \in S$ que produzca un decremento en alguno de los criterios sin causar un incremento simultáneo en alguno de los otros criterios.

En la Figura 4.1.1, se muestra el caso de un problema con dos objetivos a minimizar ($m=2$) con sus respectivas funciones objetivo $f_1(\vec{x}), f_2(\vec{x})$. En la misma, los puntos grafiados en marrón y nombrados con letras son óptimos de Pareto, pues no hay otra solución de S que consiga reducir los valores de f_1 y f_2 simultáneamente.

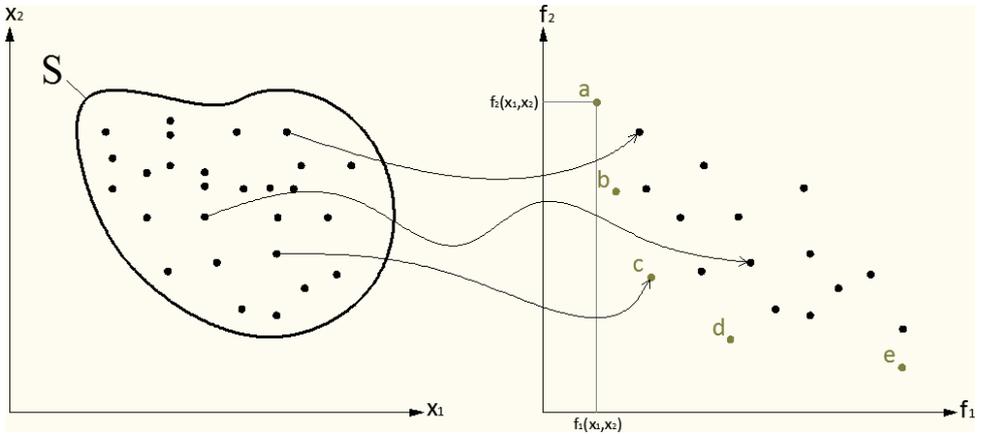


Figura 4.1.1 Las soluciones a-e son óptimos de Pareto del conjunto de soluciones S.

Dominancia de Pareto

Uno de los conceptos fundamentales de la optimización multiobjetivo basada en conjuntos de Pareto es el de dominancia de Pareto. Se dice que un vector \vec{x}_1 domina a otro \vec{x}_2 ($\vec{x}_1 \prec \vec{x}_2$) si y solo si \vec{x}_1 es parcialmente menor a \vec{x}_2 . Expresado matemáticamente:

$$\vec{x}_1 \prec \vec{x}_2 \text{ si } \forall i, k \in \{1, \dots, m\}, f_i(\vec{x}_1) \leq f_i(\vec{x}_2) \wedge \exists k : f_k(\vec{x}_1) < f_k(\vec{x}_2) \quad (4.3)$$

En el mismo ejemplo mostrado en la Figura 4.1.2, el punto **b** domina a todos los puntos grafiados en rojo, que no consiguen un valor menor en ninguno de los dos objetivos:

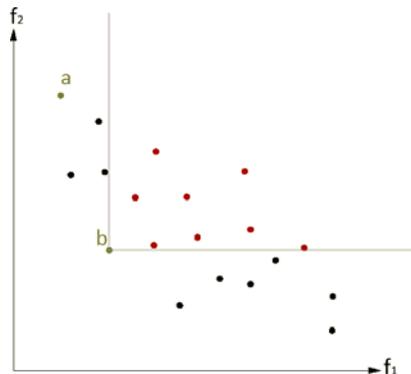


Figura 4.1.2 La solución b domina al conjunto de soluciones en rojo.

Conjunto óptimo de Pareto – Frontera de Pareto

Para un problema multiobjetivo dado $\text{Min } [f_1(\bar{x}), f_2(\bar{x}), \dots, f_m(\bar{x})]$, el conjunto óptimo de Pareto (P) se define como:

$$P = \{ \bar{x} \in S \mid \nexists \bar{x}' \in S : \bar{x}' \prec \bar{x} \} \quad (4.4)$$

Por tanto, el conjunto de Pareto de un determinado problema está formado por todas aquellas soluciones \bar{x} que no son dominadas por ninguna otra perteneciente al espacio de soluciones S . En el ejemplo mostrado en la Figura 4.1.1 y en la Figura 4.1.2, todos los puntos marrones, pertenecen al conjunto óptimo de Pareto y los rojos son puntos dominados.

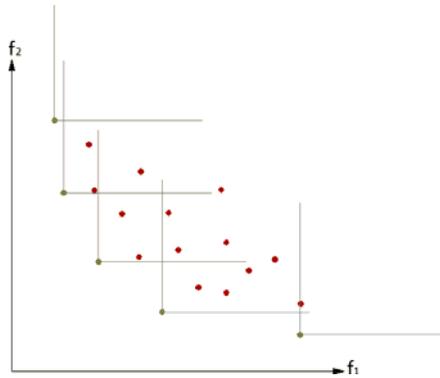


Figura 4.1.3 Conjunto óptimo de Pareto.

A la imagen del conjunto óptimo de Pareto P sobre el espacio de funciones objetivo se le denomina *frente Pareto*, o *frontera de Pareto*.

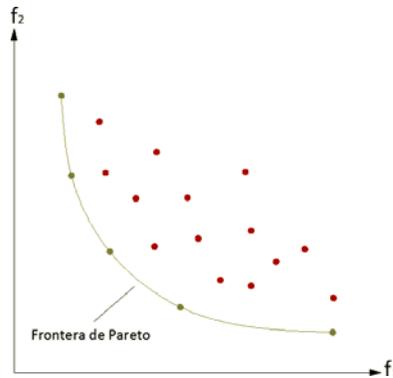


Figura 4.1.4 Representación de la frontera de Pareto

4.2 TÉCNICAS NO BASADAS EN PARETO

En la bibliografía se pueden encontrar diferentes aproximaciones multiobjetivo a los problemas de optimización combinatoria, cuyo acrónimo en inglés, que se empleará de aquí en adelante, es MOCO (*Multi Objective Combinatorial Optimization*).

En la siguiente figura se presenta una clasificación general de las diferentes técnicas encontradas:



Figura 4.2.1 Clasificación de los métodos de optimización multiobjetivo.

En un primer grupo de técnicas se pueden agrupar aquellas que no tienen su fundamento en el concepto de óptimo de Pareto o de frontera de Pareto introducidos anteriormente. En estas técnicas, se realiza o una agregación de los diferentes objetivos, conformando una única función objetivo que es la que se optimiza o bien se aborda el problema optimizando los objetivos uno a uno teniendo en cuenta el resto de objetivos como restricciones. En cada una de las técnicas se citan aplicaciones de las mismas a diferentes campos de la ingeniería, cuyas referencias se pueden encontrar en el artículo de (Coello Coello 1999).

En (Coello Coello 1998) se puede encontrar un resumen de las todas estas técnicas (denominadas como *formas simplistas de abordar el problema*), de las que se pueden destacar las siguientes:



Figura 4.2.2 Técnicas de optimización no basadas en Pareto.

4.2.1 Agregación de objetivos

Uno de los métodos más ampliamente empleados en la optimización multiobjetivo es el de la agregación de objetivos. En el mismo, se agregan todos los objetivos (de diversas formas) en una sola función, que posteriormente es minimizada o maximizada según sea el cariz del problema abordado. Coello clasifica estas técnicas como técnica de suma lineal de pesos, aunque en algunos casos es posible realizar la combinación de forma no lineal.

Esto implica que el problema con objetivos múltiples se transforma en un problema de optimización simple monoobjetivo, que puede adoptar diversas formulaciones, entre las que se pueden destacar, las aditivas (4.5) y las multiplicativas (4.6):

$$\text{Min} \sum_{i=1}^m w_i \cdot f_i(\vec{x}) \quad (4.5)$$

$$\text{Min} \prod_{i=1}^m w_i \cdot f_i(\vec{x}) \quad (4.6)$$

Donde: $w_i \geq 0$ son los pesos que representan la importancia relativa de cada uno de los objetivos. En la mayor parte de las aproximaciones, se asume que:

$$\sum_{i=1}^m w_i = 1 \quad (4.7)$$

Aunque en otras aproximaciones se pueden encontrar que los pesos son iguales a la unidad, no priorizando ninguno de los objetivos a optimizar. De esta manera y mediante este proceso de escalarización se transforma un problema de optimización vectorial en un problema de optimización convencional mono-objetivo. Dado que los resultados de resolver un problema de optimización usando la primera ecuación pueden variar significativamente conforme se modifiquen los pesos y puesto que normalmente se sabe muy poco acerca de la forma más adecuada de seleccionar estos coeficientes, se requiere resolver el mismo problema usando diferentes valores de w_i .

En este caso, el investigador todavía tiene que tomar la decisión de elegir la solución más apropiada en base a su experiencia. En capítulos posteriores, se profundiza en las diferentes aproximaciones al problema de distribución en planta mediante técnicas de agregación de objetivos, pues hay numerosas referencias que emplean esta forma de abordar el problema.

Otros campos en los que se ha empleado esta técnica son: ingeniería ambiental, diseño de controladores, diseño de filtros ópticos, diseño de antenas...

4.2.2 Método de programación por metas

La programación por metas, empleada como técnica de decisión multicriterio fue introducida por (Charnes y Cooper 1961) en este método, se deben asignar los objetivos o metas que desee alcanzar para cada una de las funciones objetivo. Estos valores se incorporan en la formulación del problema como restricciones adicionales. La técnica tratará entonces de minimizar las desviaciones absolutas de cada función objetivo con respecto a lo deseado.

La principal ventaja de estas técnicas es su simplicidad y su eficiencia computacional, dado que no se requiere realizar una jerarquización de Pareto.

La formulación de este método puede ser expresada de la siguiente manera:

$$\min \sum_{i=1}^m |f_i(\bar{x}) - T_i|, \quad / \bar{x} \in F \quad (4.8)$$

Donde: T_i es la meta u objetivo establecida para la i -ésima función objetivo $f_i(\bar{x})$

F representa el conjunto de soluciones factibles.

Este método se formuló originalmente para su aplicación en problemas industriales, aunque es en el ámbito de la economía donde más se ha empleado en los últimos años. No se ha encontrado ninguna reseña bibliográfica que aplique este método al problema de distribución en planta, sin embargo se ha empleado en el diseño de filtros IIR, en optimización estructural o en contrabalanceo de brazos de robot.

4.2.3 Método de las restricciones ϵ

Este método se basa en la minimización de una función objetivo (la principal o preferida), considerando los demás objetivos como restricciones acotadas por ciertos niveles permisibles de error ϵ_i .

Los niveles de error admitidos, los ϵ_i se podrían ir modificando para generar todo el conjunto de Pareto, aunque esto último no se ha encontrado en la bibliografía consultada. El método se formula de la siguiente manera, considerando que el objetivo r es el prioritario:

1. Encontrar el mínimo de la r -ésima función objetivo, es decir, encontrar \vec{x} tal que:

$$f_r(\vec{x}) = \min f_r(\vec{x}) \quad / \quad \vec{x} \in S \quad (4.9)$$

sujeta a restricciones adicionales de la forma:

$$f_i(\vec{x}) \leq \epsilon_i \quad i = 1, 2, \dots, u \quad ; \quad i \neq r \quad (4.10)$$

Donde: ϵ_i Nivel de error permitido para cada uno de los $m-1$ objetivos restantes.

F representa el conjunto de soluciones factibles.

2. Repetir (1) para distintos valores de ϵ_i . La información derivada de un conjunto adecuadamente seleccionado de ϵ_i puede ser útil para tomar la decisión final. La búsqueda se detiene cuando el investigador encuentra una solución satisfactoria.

Puede ser necesario repetir los pasos anteriores, considerando diferentes objetivos como principales (distintos valores de r). Para obtener valores adecuados de ϵ_i con los que realizar la optimización se efectúan optimizaciones individuales de cada una de las funciones objetivo de forma sucesiva, usando técnicas de programación matemática. Para cada función objetivo $f_i (i=1, 2, \dots, m)$, hay un vector de diseño óptimo \vec{x} para el cual $f(\vec{x})$ es el mínimo.

No se ha encontrado, en la bibliografía consultada, ninguna publicación del problema de distribución en planta optimizado con éste método, sin embargo se ha aplicado a problemas como el diseño preliminar de vehículos marinos, en contaminación de acuíferos, en el diseño de sistema tolerantes a fallos y en problemas de ingeniería ambiental.

4.2.4 VEGA (Vector Evaluated Genetic Algorithm)

La primera implementación de lo que se conoce actualmente como algoritmos evolutivos multiobjetivo (MOEA) fue VEGA (*Vector Evaluation Genetic Algorithm*) introducido por (Schaffer 1984) en la década de los 80 y su principal aportación fue resolver problemas de inteligencia artificial. VEGA básicamente consiste en un algoritmo genético con una modificación en el mecanismo de selección. En cada iteración un número de subpoblaciones se generan de acuerdo a una selección proporcional a cada una de las funciones objetivo, sin embargo, la aproximación que se hace no tiene en cuenta el concepto de óptimo de Pareto.

En un problema con m funciones objetivo se genera m subpoblaciones de tamaño N/m . Estas se mezclan luego entre sí a fin de obtener una nueva población de tamaño N , en la que el algoritmo genético aplica los operadores de cruzamiento y mutación de la forma habitual.

Schaffer se percató de que las soluciones generadas por su sistema eran no dominadas localmente, porque esta no dominancia se limitaba a la población en proceso y aunque un individuo dominado localmente es dominado también globalmente, esta propiedad no aplica necesariamente a la no dominancia.

Un individuo que es no dominado en una cierta generación, puede resultar dominado por otro que emerja en una generación posterior. También advirtió un problema al que se denomina en genética como *especiación*, fenómeno consistente en que ciertas especies con características específicas evolucionan en direcciones distintas. Este problema se origina porque esta técnica selecciona individuos que son excelentes en unas determinadas funciones objetivo pero no necesariamente en las otras.

La ventaja de esta técnica es su facilidad de implementación y su eficiencia, y su principal desventaja es que si se usa una selección proporcional es equivalente a una combinación lineal de pesos, y no incorpora el concepto de dominancia de Pareto.

Algunos de los usos en los que se ha empleado esta técnica son: en contaminación de acuíferos, en colocación de actuadores, y en el diseño de circuitos combinatorios a nivel de compuertas.

4.2.5 Ordenamiento Lexicográfico

En este método, el investigador jerarquiza los u objetivos a optimizar, estableciendo un orden de importancia. La solución óptima \bar{x} se obtiene minimizando (o maximizando) las funciones objetivo por separado, empezando con la más importante y procediendo de acuerdo con el orden de importancia asignado a cada uno de los objetivos.

Si los subíndices de los objetivos indican no sólo el número de funciones objetivo al que corresponden, sino también la prioridad de cada objetivo, las funciones $f_1(\bar{x})$ y $f_u(\bar{x})$ denotan las funciones objetivo de mayor y menor importancia respectivamente.

El problema correspondiente al primer objetivo se formula de la siguiente forma:

$$\begin{aligned} \text{Min } f_1(\bar{x}) \\ \text{sujeto a: } g_j(\bar{x}) \leq 0; \quad j=1,2,\dots,u \end{aligned} \quad (4.11)$$

Obteniendo de esta forma la solución \bar{x} y $f_1^* = f_1(\bar{x})$.

Posteriormente, se van formulando el resto de problemas, para cada uno de los objetivos:

$$\begin{aligned} \text{Min } f_l(\bar{x}) \\ \text{sujeto a: } g_j(\bar{x}) \leq 0; \quad j=1,2,\dots,u \\ f_l(\bar{x}) = f_l^* \quad ; \quad l=1,2,\dots,i-1 \end{aligned} \quad (4.12)$$

La solución final obtenida en la optimización del último objetivo, \bar{x}_m , se considera como la solución deseada al problema. Este método es una variación de la programación por metas comentada anteriormente.

La mayor ventaja de esta técnica es su simplicidad, lo cual conlleva asociada una enorme eficiencia computacional. Su principal desventaja es que el desempeño de la técnica depende totalmente del ordenamiento impuesto sobre las funciones objetivo. Suele usarse con 2 o 3 funciones objetivo.

En la optimización del problema de distribución en planta de establecimientos industriales, no hay ninguna referencia publicada aplicando este método, sin embargo se ha empleado en problemas como la compactación de circuitos, en problemas de horarios...

4.2.6 Algoritmos MiniMax

En algunas referencias, se puede encontrar la resolución de problemas de optimización combinatoria mediante una técnica de decisión empleada en teoría de juegos, en las que se aborda la solución de situaciones conflictivas, como es el algoritmo Minimax.

La técnica del óptimo Min-Max compara las desviaciones relativas de los mínimos deseados por separado. Uno de los problemas de aplicar esta técnica es que todas las funciones objetivos tienen el mismo peso, por tanto no se puede establecer una prioridad en el cumplimiento de los mismos.

En el caso de estar estudiando la optimización de m objetivos, para el objetivo i -ésimo se puede calcular las desviaciones relativas:

$$z'_i(x) = \left| \frac{f_i(\bar{x}) - f_i^0}{|f_i^0|} \right| \quad (4.13)$$

y:

$$z''_i(x) = \left| \frac{f_i(\bar{x}) - f_i^0}{|f_i(\bar{x})|} \right| \quad (4.14)$$

En ambos casos, $f_i^0 = \min f_i(\bar{x})$, si todos los objetivos se minimizan, la ecuación (4.13) define incrementos relativos, mientras que si todas se van a maximizar, define decrementos relativos.

Se genera un vector de los incrementos relativos: $\bar{z}(\bar{x}) = (z_1(\bar{x}), \dots, z_i(\bar{x}), \dots, z_m(\bar{x}))^T$, en el que las componentes del mismo se evalúan a partir de la ecuación (4.15):

$$z_i(\bar{x}) = \max \{ z'_i(\bar{x}), z''_i(\bar{x}) \} \quad (4.15)$$

Una vez conocidos los extremos de las u funciones objetivo, obtenidos mediante la optimización por separado de cada uno de ellos, se define el óptimo MiniMax como la solución que proporciona los valores más pequeños para los incrementos relativos $z_i(\bar{x})$ de todas las funciones objetivo.

Es muy poco significativa la presencia de este algoritmo en los problemas de optimización combinatoria, y en el caso del problema de distribución en planta es nula.

4.3 TÉCNICAS BASADAS EN PARETO

La incorporación de los conceptos de optimidad de Pareto fueron introducidos por primera vez en (Goldberg 1989), para resolver alguno de los problemas derivados del uso de VEGA. La idea básica era encontrar el conjunto de cadenas en la población que sean no dominadas, asignándoles la jerarquía más alta y eliminándolas de la población. Se procede de la misma forma con el resto de cadenas, hasta que todos los elementos de la población quedan jerarquizados.

El enfoque basándose en dominancia de Pareto, permite realizar la optimización de una manera íntegra, teniendo en cuenta todos los objetivos al mismo tiempo, e integrándolos en heurísticas que permiten realizar una optimización eficiente del problema.

El numero de técnicas es muy variado, pudiéndose realizar una primera agrupación en función de la metaheurística mediante la cual se realiza la optimización, así existe un numeroso grupo basado en algoritmos bioinspirados, todos ellos poblacionales, y un segundo grupo basado en técnicas de *Simulated Annealing*.

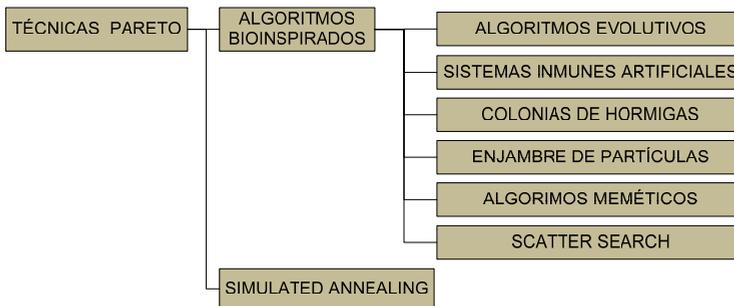


Figura 4.3.1 Técnicas de optimización basadas en Pareto.

4.3.1 Algoritmos Evolutivos Multi-Objetivo - MOEA

Desde la segunda mitad de los años 80 se han venido desarrollando multitud de algoritmos genéticos multiobjetivo, pero no fue hasta la década de los 90 cuando comenzó a tratarse el problema con la óptica Pareto. En todos estos años se han desarrollado y aplicado numeroso algoritmos MOEA (*Multi-Objective Evolutionary Algorithms*) a problemas de optimización, entre ellos el problema de distribución en planta, objeto del presente trabajo.

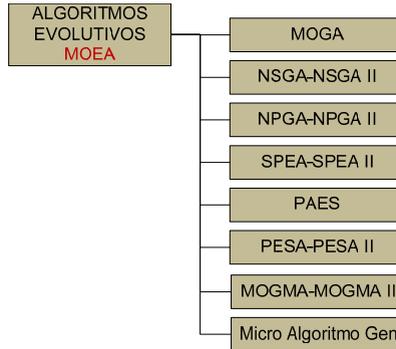


Figura 4.3.2 Técnicas de optimización MOEA basadas en Pareto.

Desde la aparición del primer algoritmo evolutivo multiobjetivo empleando el concepto de óptimo de Pareto (Goldberg 1989), se han publicado numerosos estados del arte en los que se recogen las publicaciones más notorias en este campo, entre los que destacan: (Fonseca y Fleming 1995), (Tamaki, Kita y Kobayashi 1996), y uno de los más recientes (Coello Coello 2006). Por último en (Coello Coello 2009) se hace una descripción de los últimos esfuerzos realizados en este campo, que demuestra estar, a tenor de las publicaciones, muy vivo.

En los últimos años se han publicado un número muy elevado de referencias (tanto artículos, capítulos de libros, conferencias...) empleando algoritmos evolutivos en problemas multiobjetivo, cuyas referencias han sido recopiladas por el profesor Coello en un repositorio en internet¹ en el que se pueden encontrar hasta 3000 entradas.

A continuación se describen, cronológicamente, los algoritmos más destacados en el campo de los MOEA. Coello en una de sus revisiones establece una diferencia entre las tres primeras técnicas (NSGA, NPGA y MOGA) a las que llama técnicas de primera generación y las restantes, llamadas de segunda generación. La diferencia fundamental es que las de la primera generación únicamente buscaban simplemente hacer una técnica que fuera funcional, mejorando el camino emprendido por VEGA, a partir del momento en el que se vio que los MOEAs eran eficientes, se comenzó a buscar una mayor eficiencia de las técnicas, reduciendo tiempos de computación y mejorando la forma de la frontera.

¹ <http://www.lania.mx/~ccoello/EMOO>

4.3.1.1 MOGA (Multi Objective Genetic Algorithm)

(Fonseca y Fleming 1993) propusieron la primera técnica evolutiva tras la jerarquización de Pareto propuesta por Goldberg, en la cual la jerarquía de un cierto individuo corresponde al número de cromosomas por los cuales es dominado en la población actual.

Consideremos, por ejemplo, a un individuo x_i en la generación t , el cual es dominado por p_i^t individuos de la generación actual. Su posición actual en la jerarquía puede obtenerse mediante:

$$\text{jerarquía}(x_i, t) = 1 + p_i^t \quad (4.16)$$

A todos los individuos no dominados se les asigna la *jerarquía*=1, mientras que a los dominados se les penaliza de acuerdo a la densidad de la población en la región correspondiente de la frontera de Pareto. La asignación de aptitud se efectúa de la manera siguiente:

1. Ordenar la población de acuerdo a la jerarquía de los individuos.
2. Asignar aptitud a los individuos interpolando entre el mejor (*jerarquía*=1) y el peor (*jerarquía*= $n \leq N$) calculada de la forma propuesta por Goldberg, con una interpolación que generalmente (aunque no de forma necesaria) es lineal.
3. Promediar las aptitudes de los individuos que tengan la misma jerarquía, de manera que todos ellos sean muestreados con la misma probabilidad. Este procedimiento mantiene la aptitud global de la población constante, a la vez que mantiene una presión de selección apropiada de acuerdo a la función utilizada.

Uno de los problemas que inicialmente se atribuyeron a la técnica de jerarquización pura de Goldberg es este tipo de asignación de aptitud con bloqueo suele producir una gran presión de selección que puede conducir a una convergencia prematura. Para evitar este problema, (Fonseca y Fleming 1993) usaron un método de formación de nichos para distribuir la población sobre el frente de Pareto.

En MOGA, la repartición de aptitud se efectúa en el espacio de los valores de las funciones objetivo, lo que significa que dos vectores diferentes con los mismos valores para sus funciones objetivo no pueden existir simultáneamente en la población usando esta técnica. Esto es, aparentemente, indeseable porque este es precisamente el tipo de soluciones que normalmente se buscan, aunque debe decirse que a nivel práctico la técnica de Fonseca y Fleming funciona de una forma correcta y tiene la ventaja de que existe una nutrida bibliografía al respecto.

MOGA es una buena técnica, eficiente y relativamente fácil de implementar, aunque, al igual que todas las demás técnicas de jerarquización de Pareto, su desempeño depende en gran medida de una selección adecuada del factor de repartición de aptitud.

Esta técnica ha sido empleada en diferentes campos, pudiendo destacar el diseño de controladores magnéticos, en optimización de armaduras planas o en manejo de bosques. En los últimos años se han realizado algunos esfuerzos para utilizar MOGA, hibridado con redes neuronales (Duarte et al. 2000) y agregando elitismo (Ducheyne, De Wulf y De Baets 2001), aunque es una técnica que ha sido claramente desplazada por los algoritmos de segunda generación.

4.3.1.2 NSGA (Nondominated Sorting Genetic Algorithm) y NSGA-II

Esta técnica fue propuesta por (Srinivas y Deb 1994), y se basa en el uso de varias capas de clasificación de los individuos. Antes de efectuar la selección, la población es jerarquizada en base a la dominación de cada uno de los componentes de la misma.

Todos los individuos no dominados se clasifican en un primer grupo (con un valor arbitrario de aptitud, que es proporcional al tamaño de la población, a fin de proporcionar un potencial reproductivo equitativo para estos individuos).

Posteriormente, se obtienen los individuos no dominados de la población restante, configurando así el segundo grupo (o capa). Este proceso se repite hasta que todos los individuos de la población estén clasificados. La técnica utiliza selección proporcional (la variante llamada *stochastic remainder*).

Debido a que los individuos de la primera capa tienen el máximo valor de aptitud, siempre consiguen tener un mayor número de copias que el resto de la población. Esto permite buscar regiones no dominadas, y produce convergencia rápida de la población hacia estas regiones. El reparto de aptitud, por su parte, ayuda a distribuir los individuos sobre esta región. La eficiencia del NSGA reside en que los objetivos múltiples de un problema se reducen a una función de aptitud arbitraria usando un procedimiento de ordenamiento basado en no dominancia.

En este caso el reparto de la aptitud se efectúa en base a los valores de los parámetros en vez de en base a los valores de las funciones objetivo, lo cual pretende asegurar que se lleve a cabo una mejor distribución de los individuos, así como permitir que existan múltiples soluciones equivalentes. Sin embargo, esta técnica es más ineficiente que el resto de técnicas de primera generación (tanto computacionalmente como en términos de la calidad de los frentes de Pareto que produce).

Esta técnica se ha empleado en el control de la calidad del agua, en el diseño de sistemas de control o en problemas de dinámica de fluidos.

Una segunda versión de esta técnica se publicó en (Deb et al. 2000), en la que se emplea un operador de cruzamiento en vez de emplear nichos. Además de contar con el uso de elitismo es mucho más eficiente que su predecesora y es un algoritmo muy competitivo. Zitzler detectó que el algoritmo tiende a tener problemas exploratorios, sobre todo si el número de funciones objetivo es elevado.

4.3.1.3 NPGA (Niche-Pareto Genetic Algorithm) y NPGA-II

(Horn, Nafpliotis y Goldberg 1994) propusieron NPGA, una técnica basada en la selección mediante una competición entre individuos. Se seleccionan aleatoriamente dos individuos de la población y se les compara con un subconjunto de la población (de alrededor de 10 individuos). Gana la competición aquel de los dos individuos que resulte no dominado por ningún individuo del subconjunto.

Cualquier otra situación (ambos no dominados o ambos dominados) se considera un empate y se debe proceder al desempate, que se resuelve mediante una repartición de aptitud. Normalmente se deben usar poblaciones considerablemente mayores de lo habitual, para hacer tolerable el ruido producido por la técnica de selección utilizada para los nichos emergentes (Fonseca y Fleming 1995).

(Horn, Nafpliotis y Goldberg 1994) llegaron a una forma de repartición de aptitud en el dominio de las funciones objetivo, y sugirieron el uso de una métrica en la que se combinan los dominios de las variables de decisión con el de las funciones objetivo, lo que condujo a lo que ellos denominaron repartición anidada de aptitud.

Puesto que esta técnica no aplica la selección de Pareto a toda la población, sino sólo a un segmento de ella en cada arranque, su ejecución resulta muy rápida y produce buenas fronteras de Pareto que suelen mantenerse durante un gran número de generaciones. Sin embargo, además de requerir un factor de repartición de aptitud (que hay que asignar), esta técnica también requiere que se elija cuidadosamente el tamaño de la competición, ya que de él depende en gran medida su desarrollo.

(Erickson, Mayer y Horn 2002) propusieron NPGA-II, una versión revisada del NPGA. Este algoritmo utiliza jerarquización de Pareto pero mantiene la selección por torneo del NPGA. En este caso, no hay memoria externa y el mecanismo elitista es similar a uno adoptado por NSGA II. El contorno del nicho en el NPGA II se calcula utilizando individuos en la siguiente generación parcialmente completa, en lugar de utilizar la generación actual. A esto se le conoce como actualización continua y fue propuesto por (Oei, Goldberg y Chang 1991).

4.3.1.4 SPEA (*Strength Pareto Evolutionary Algorithm*) y SPEA-II

Este algoritmo fue introducido por (Zitzler y Thiele 1998) y el enfoque fue concebido como un camino para integrar las diferentes técnicas de primera generación, intentando combinar las mejores características de cada uno de ellos. SPEA utiliza un archivo que contiene soluciones no dominadas previamente encontradas, en cada una de las nuevas generaciones, los individuos no dominados son copiados al conjunto de no dominados externo. Para cada individuo en este conjunto externo, se calcula un valor de clasificación. Este valor es similar al valor de clasificación de MOGA, y que es proporcional al número de soluciones a las que un cierto individuo domina. Con SPEA comienza una segunda generación de algoritmos evolutivos, al introducir el uso de elitismo, se ha podido demostrar que el uso de elitismo es necesario para garantizar la convergencia de un algoritmo evolutivo multiobjetivo a la verdadera frontera de Pareto.

SPEA se ha empleado para la planificación de tratamientos médicos, diagnóstico de enfermedades,

Posteriormente vería la luz SPEA-II (Zitzler, Laumanns y Thiele 2001) que tiene tres diferencias fundamentales con respecto a su predecesor:

1. La incorporación de una mejora de la estrategia empleada para asignar la aptitud de cada individuo de la población, teniendo en cuenta el número de soluciones que domina y la cantidad de individuos que la dominan.
2. Utiliza una técnica para estimar la densidad de vecinos de una determinada solución, que guía la búsqueda de una manera más eficiente.
3. Tiene un esquema de truncamiento de archivos que garantiza la preservación de soluciones de la frontera.

El SPEA-II se ha empleado en el diseño de aeronaves.

4.3.1.5 PAES (*Pareto Archived Evolution Strategy*)

PAES fue introducido por (Knowles y Corne 1999) y emplea una estrategia de evolución sencilla, de 2 miembros (un padre que es mutado para generar un hijo) y cuya clave el empleo de una rejilla adaptativa para retener a los individuos no dominados obtenidos, distribuyéndolos uniformemente. Esta técnica ha sido empleada en problemas de telecomunicaciones y en el manejo de bases de datos adaptativas.

4.3.1.6 PESA (Pareto Envelope-based Selection Algorithm) y PESA-II

Este algoritmo fue propuesto por (Corne, Knowles y Oates 2000), en el que se utiliza una población pequeña interna y una población grande externa como en PAES.

Utiliza la rejilla adaptativa de PAES para mantener la diversidad, sin embargo, este mecanismo de selección está basado en la medida de agrupamiento usada por la rejilla auto-adaptativa.

En PESA la memoria externa juega un papel muy importante en el algoritmo dado que esta determina no solamente el esquema de diversidad, sino también la selección desarrollada por el método.

Posteriormente (Corne, Jerram y Knowles 2001) proponen un algoritmo modificado, PESA-II, cuya única diferencia es que emplea una selección basada en regiones y no en individuos, lo que implica una reducción del costo computacional.

4.3.1.7 MOMGA (Multi Objective Messy Genetic Algorithm) y MOMGA-II

(Van Veldhuizen y Lamont 2000) proponen este algoritmo que trata de extender las características del messy GA a un problema multiobjetivo. Los autores diferencian 3 fases:

1. *Fase de inicialización.* En la que el algoritmo produce todos los bloques constructores de un determinado tamaño fijado.
2. *Fase primordial.* Se efectúa una selección mediante torneo en la población, reduciendo el tamaño de la misma si fuera necesario.
3. *Fase Yuxtaposicional.* Se construye la población nueva mediante los operadores corte y unión.

Se ha empleado esta técnica en el diseño de controladores y en funciones de prueba tradicionales.

En (Zydallis, Van Veldhuizen y Lamont 2001) presentaron una evolución de la técnica, denominada MOMGA-II, en la que se extiende el *fast messy GA*, aplicado a funciones de prueba tradicionales.

4.3.1.8 *MicroGA (Micro Algoritmo Genetico MicroGA) y MicroGA-II*

Propuesto por (Coello Coello y Toscano 2001), este es un algoritmo genético con una población pequeña (menos de 5 individuos) y un proceso de reinicialización cada vez que se alcanza convergencia nominal. Primero, genera una población aleatoria, esta población aleatoria nutre a la memoria de la población, la cual se divide en dos partes: una reemplazable y otra no reemplazable. La porción no reemplazable de la memoria de la población nunca cambia durante toda la ejecución y es mala para proporcionar la diversidad requerida por el algoritmo. En contraste, la experiencia de la porción reemplazable cambia después de cada ciclo del micro GA.

El microGA es un algoritmo muy rápido en comparación con otros algoritmos eficientes como el NSGA-II, el mayor inconveniente del algoritmo es que requiere un elevado número de parámetros (hasta ocho, 3 de los cuales son críticos para su correcto funcionamiento). Esta técnica se ha empleado en diseño estructural y en el diseño de aviones.

Buscando eliminar la desventaja fundamental del micro GA, los mismos autores, propusieron el microGA-II (Toscano Pulido y Coello Coello 2003), que usa mecanismos de adaptación en línea, que hacen que el algoritmo no requiera ningún parámetro. El único parámetro que el usuario debe proporcionar es el tamaño de la población secundaria, pues el mismo algoritmo es capaz de decidir el momento de la parada.

4.3.2 Sistemas Inmunes Artificiales Multi-Objetivo - MOAIS

Desde un punto de vista computacional, nuestro sistema inmune puede ser visto como un sistema inteligente, que es capaz de aprender y reproducir conocimiento previamente adquirido. Algunos investigadores han reproducido la forma de actuar del sistema inmune para una gran variedad de problemas ya sean de reconocimiento, clasificación o de optimización, mediante una metaheurística conocida como AIS (*Artificial Immune System*).

El primer uso específico del sistema inmune en problemas de optimización se remonta a 1999, donde Yoo y Hajela emplearon un algoritmo genético donde el principio de inmunidad anticuerpo-antígeno se emplea para modificar el valor de ajuste.

Desde ese momento, se pueden encontrar extensiones del AIS a la optimización multiobjetivo, también conocidas como MOAIS (*MultiObjective Artificial Immune System*), e incluso un estado del arte en (Freschi y Coello Coello 2009) en el que se recogen las aportaciones al problema por los diferentes investigadores, y en el que se describen los diferentes algoritmos (12 en concreto) propuestos desde 2002 a 2007, de entre los que se pueden destacar:

- MISA (*Multiobjective Immune System Algorithm*), es un algoritmo que se ha ido actualizando hasta la última versión de 2005 (Coello Coello y Cruz Cortés 2005), destaca por ser la primera aplicación de AIS en un problema multiobjetivo.
- omni-aiNet, propuesto en (Coelho y Von Zuben 2006) tiene la peculiaridad que permite lidiar con problemas mono y multiobjetivo con AIS.
- QUICMOA, propuesto en (Li y Jiao 2007) que hibrida una técnica basada en un algoritmo cuántico con AIS.

En la misma publicación, se hace una referencia a los campos donde se ha empleado un algoritmo de optimización multiobjetivo basado en Sistemas Inmunes Artificiales, de entre los que destacan:

- Optimización de redes de distribución eléctricas
- Biomedicina
- Investigación operativa

Tal y como se verá en capítulos posteriores, existe una referencia en la bibliografía en la que se aplica un algoritmo MOAIS al problema de distribución en planta.

4.3.3 Colonias de Hormigas Multi-Objetivo - MOACO

Esta metaheurística fue propuesta por (Dorigo 1992), (Colorni, Dorigo y Maniezzo 1992) y está inspirada en el comportamiento explorador de las hormigas, también se ha empleado en problemas de optimización multiobjetivo. Se basa en la comunicación indirecta de un conjunto de hormigas artificiales a través del rastro de feromonas que dejan al recorrer un camino. Estos rastros pueden ser vistos como información distribuida y es empleada por las hormigas para construir las soluciones del problema con el que están lidiando.

Se puede encontrar la extensión a un algunos problemas con múltiples objetivos en un limitado número de referencias bibliográficas, de entre las que se puede destacar (Guntsch y Middendorf 2003) o (García-Martínez, Cerdón y Herrera 2004), en la que se realiza una revisión de las aplicaciones de ACO al problema bicriterio del TSP.

Se espera que en los próximos años, y debido al auge de los problemas de optimización combinatoria multiobjetivo, este tipo de algoritmos sean desarrollados con mayor intensidad, tal y como lo destacan Coello, Erghott y Gandibleux en alguna de sus publicaciones de resumen del campo.

4.3.4 Enjambre de partículas Multi-Objetivo (Particle Swarm Optimization)

Esta metaheurística fue introducida por (Kennedy y Eberhart 1995) y está inspirada en el movimiento colectivo de grupos de animales, como pájaros, peces o enjambres de abejas. Este es un algoritmo distribuido y que sirve para realizar una búsqueda multidimensional.

Desde el primer intento de ampliar esta técnica a problemas con múltiples objetivos (Moore y Chapman 1999) se han realizado diferentes aportaciones que la han situado como una de las técnicas emergentes en este campo.

En (Reyes-Sierra y Coello Coello 2006) se realiza un estado del arte de las publicaciones realizadas en el ámbito de esta técnica de optimización, en el que se recogen cerca de una treintena de aportaciones en las que se aplica PSO a problemas de optimización multiobjetivo.

Hasta hace poco tiempo, las publicaciones en este campo se centraban en realizar aplicaciones directas del algoritmo, más que en producir variantes del original, sin embargo, en los últimos años, los investigadores se han centrado en realizar variaciones en algunos de los elementos fundamentales del mismo, que habitualmente habían sido ignoradas (por ejemplo, el mecanismo de selección del líder o los parámetros de la fórmula del vuelo) lo que hace que se abran nuevas vías en este campo.

No se han encontrado en la bibliografía publicaciones aplicadas al problema de distribución en planta multiobjetivo con esta metaheurística.

4.3.5 Algoritmos Meméticos Multi-Objetivo

Los algoritmos meméticos son una metaheurística evolutiva similar a los algoritmos genéticos, que en las últimas décadas ha sido utilizada en problemas de optimización, tanto mono como multiobjetivo.

Los orígenes de los algoritmos meméticos (MA) se remonta a finales de los años ochenta, época en la que la computación evolutiva estaba comenzando a consolidarse. En este escenario surge la idea básica que sustenta los algoritmos meméticos; combinar conceptos y estrategias de diferentes metaheurísticas extrayendo las ventajas de cada una de ellas.

La denominación de memético surge del término inglés meme, acuñado por R. Dawkins como el análogo del gen en el contexto de la evolución cultural:

“...ejemplos de memes son melodías, ideas, frases hechas, modas en la vestimenta, formas de hacer vasijas o de construir bóvedas. Del mismo modo que los genes se propagan en el acervo genético a través de gametos, los memes se propagan en el acervo memético saltando de cerebro a cerebro en un proceso que, en un amplio sentido, puede denominarse imitación.”

(Dawkins 1986)

De esta definición se puede extraer la idea central de los algoritmos meméticos, realizar mejoras individuales de las soluciones junto con procesos de cooperación y competiciones de tipo poblacional. El algoritmo mantiene en todo momento una población de diversas soluciones (o agentes) del problema considerado. La interacción entre los agentes se estructura en una sucesión de grandes pasos temporales (llamados generaciones). Cada generación consiste en la actualización de la población, obtenida mediante la combinación de las mejores características de los distintos agentes. En cada generación se dan tres pasos fundamentales:

1. Selección
2. Reemplazo
3. Reproducción

Tanto la selección como el reemplazo son procesos únicamente competitivos en los que solo varía la distribución de los agentes existentes, esto es, no se crean nuevos agentes en estas fases, algo que queda reservado para la etapa de reproducción.

Se puede encontrar una introducción al uso de este tipo de algoritmos en optimización multiobjetivo en (Knowles y Corne 2004), donde se introduce el campo de la optimización multiobjetivo y posteriormente se citan las aportaciones más importantes aparecidas en los últimos años.

En la actualidad existen un número bastante limitado de autores que apliquen este tipo de algoritmos a problemas multiobjetivo, pudiéndose diferenciar tres grandes aportaciones:

- MOGLS (*MultiObjective Genetic Local Search*), propuesto por (Ishibuchi y Murata 1996)
- RD-MOGLS (*Random Direction MOGLS*), propuesto por (Jaszkiewicz 1998) y su variación posterior, el PMA (*Pareto Memetic Algorithm*).
- M-PAES, propuesta en (Knowles y Corne 2000).

Mientras que los dos primeros algoritmos aplican una función escalarizante para jerarquizar las soluciones y seleccionar aquellas que generarán las nuevas soluciones, el enfoque de M-PAES va más en la línea de generar un conjunto de soluciones eficientes (frontera de Pareto) del que surgirá una nueva generación de soluciones.

4.3.6 Scatter Search Multi-Objetivo

Scatter Search o búsqueda esparcida, es un algoritmo poblacional que construye nuevas soluciones mediante la combinación de soluciones intermedias. La idea era generar nuevas reglas mediante una combinación pesada de reglas existentes. Después se extendió a una combinación pesada de restricciones para reflejar la intensidad con la que se incumplen ciertas restricciones (*surrogate constraints*).

Opera sobre un conjunto de soluciones (*reference points*), que constituyen “buenas” soluciones obtenidas en pasos anteriores. Posteriormente, el algoritmo genera sistemáticamente combinaciones de estos puntos de referencia para obtener nuevas soluciones. Se realizan combinaciones lineales de las soluciones, acompañadas de procesos adaptativos para garantizar condiciones de factibilidad.

El algoritmo opera de la siguiente forma:

1. Se genera un conjunto inicial de soluciones que garantice cierto nivel de diversidad. Selecciona un subconjunto de las mejores soluciones, en cuanto a evaluación de función objetivo y diversidad.
2. Se crean nuevas soluciones mediante combinaciones de subconjuntos de las soluciones de referencia. Se buscan soluciones tanto dentro como fuera de las regiones convexas de las soluciones de referencia y su posible modificación para hacerlas aceptables (soluciones factibles).
3. Extrae las mejores soluciones y las añade al conjunto de soluciones de referencia.

Tal y como se puede leer en (Coello Coello 2009), la extensión de las técnicas *Scatter Search* a los problemas de optimización multiobjetivo son relativamente recientes, pero se han ido produciendo avances en este sentido. Así, se pueden encontrar algunas referencias como (Nebro, Luna y Alba 2005) y (Beausoleil 2006).

Esta técnica, debido a su flexibilidad y facilidad de uso, es particularmente interesante para realizar hibridaciones con otras técnicas de optimización, como los algoritmos meméticos o *Tabú Search*.

4.3.7 Evolución Diferencial Multi-Objetivo

Uno de los últimos algoritmos evolutivos propuestos en el campo de la optimización en espacios continuos es la Evolución Diferencial (en adelante ED), introducida en (Price y Storn 1996). Esta heurística comparte algunas singularidades con los algoritmos genéticos, pero tiene ligeras diferencias que obligan a considerarlo como una heurística diferente. Una descripción más detallada del algoritmo se puede encontrar en (Price 1999).

La ED, comparte algunas características con el resto de los algoritmos evolutivos:

- Es un algoritmo poblacional.
- Se utilizan operadores de recombinación y mutación para generar nuevas soluciones.
- Se emplea un mecanismo de reemplazo para mantener el tamaño de la población.

Los rasgos característicos de la ED son:

- Las soluciones obtenidas son codificadas con valores reales.
- No se utiliza una distribución fija para controlar el comportamiento del operador mutación, sino que se deja que la distribución de las soluciones obtenidas en el espacio determine la dirección de búsqueda.

La evolución diferencial emplea un operador mutación basado en evaluar las diferencias entre pares de soluciones (llamadas también vectores), que marcarán la dirección de búsqueda basándose en la distribución de soluciones de la población actual. Asimismo emplea un mecanismo de reemplazo estacionario, donde la nueva generación compite solo contra sus progenitores y los reemplaza si tiene un mejor valor de ajuste. En este campo, a la nueva generación se le llama *vector de prueba* y a los progenitores *vector viejo*.

El mecanismo de funcionamiento del algoritmo y sus diferentes variantes es el siguiente; se selecciona un elemento de la población actual de tamaño fijo, que pasará a denominarse *vector donante* (en la figura \mathbf{x}_{r3}), el mismo se puede determinar de manera aleatoria (*random*) o emplear el mejor de la población actual (*best*). A este vector se le aplica un operador mutación, para generar un nuevo elemento de la población (*vector mutación*, punto cuadrado negro en la figura), este operador emplea una dirección de búsqueda que se determina a través del empleo de uno o más pares de elementos de la población, que se obtienen siempre forma aleatoria (en la figura \mathbf{x}_{r1} y \mathbf{x}_{r2}). Por último se determinan los miembros de la nueva generación (marcados como cuadrados en la figura), empleando un operador sobre el *vector mutación* y el progenitor (\mathbf{x}_i en la figura). El operador puede ser binomial o exponencial.

Las variantes más comunes del algoritmo son:

1. Variantes con operador de recombinación discreto: en las mismas se emplean operadores binomiales o exponenciales, y las soluciones empleadas para obtener el vector de dirección son aleatorias o bien las mejores de la población.
 - DE/rand/1/bin
 - DE/rand/1/exp
 - DE/best/1/bin
 - DE/best/1/exp
2. Variantes con recombinación aritmética: La diferencia entre ambas reside en la forma en la que se determina el vector donante, en el primer caso se realiza de forma aleatoria y en la segunda se emplea la mejor solución de la población actual.
 - DE/current-to-rand/1
 - DE/current-to-best/1
3. Variantes con recombinación mixta:
 - DE/current –to-rand/1/bin

Además de los parámetros típicos de los algoritmos genéticos (número de individuos y número de generaciones), se adoptan dos adicionales en ED, como son:

- CR; controla la influencia de los progenitores en las nuevas generaciones. Valores mayores implican una menor influencia.
- F; escala la influencia del conjunto de pares de soluciones seleccionadas para calcular el valor de la mutación.

En (Mezura-Montes, Reyes-Sierra y Coello Coello 2008) se puede encontrar una revisión del estado del arte de ésta heurística aplicada a los problemas de optimización multiobjetivo (también conocida como MODE), en el mismo se realiza una clasificación de las diferentes formas de abordar el problema, siguiendo los mismos criterios que se pueden encontrar para el resto de heurísticas:

4.3.7.1.1 No basadas en Pareto

En este grupo se enmarcan las aplicaciones que no tienen en cuenta el concepto de óptimo de Pareto, sino que utilizan uno de los objetivos como restricción o la agregación de los objetivos obteniendo una única solución como óptimo global del problema.

En la referencia indicada anteriormente se pueden encontrar dos aproximaciones al problema enmarcadas en este grupo.

4.3.7.1.2 Basadas en Pareto

Dominancia de Pareto

En algunas de las aproximaciones, se utiliza la dominancia de Pareto como criterio para seleccionar la mejor solución entre la población vieja para determinar el vector donante y los elementos que determinan el vector de búsqueda.

En el estado del arte se pueden encontrar una decena de aportaciones desde este enfoque a problemas multiobjetivo, de entre los que se pueden destacar algunas técnicas como:

- *Pareto Differential Evolution* (PDE): Establecida en (Abass 2001) tiene algunas versiones modificadas, introducidas por el mismo autor en 2002, como son: SPDE (*Self-Adaptive PDE*) y MPANN (*Memetic Pareto Artificial Neural Networks*).
- Generalized Differential Evolution (GDE): Establecida en (Lampinen 2001) y mejorada en (Kukkonen y Lampinen 2004), con el nombre de GDE2.
- ε -MyDE: Propuesto en (Santana-Quintero y Coello Coello 2005), en el que se establecen dos poblaciones y se aplica el concepto de ε -dominancia, es decir no se permiten dos soluciones no dominadas con una distancia inferior a ε_i .

Pareto Ranking

Aquí se enmarcan aquellas aproximaciones donde se ha incluido un procedimiento de ranking de Pareto. El objetivo es realizar una selección posterior a la generación de los vectores de prueba en la población actual. Algunas de las referencias que aplican esta aproximación para resolver problemas, y que se pueden encontrar en el estado del arte comentado anteriormente son:

- Pareto Based Differential Evolution (PBDE): Propuesto en (Madavan 2002), utiliza algunos aspectos recogidos por Deb en NSGA-II y los aplica a la Evolución Diferencial.
- Multi-Objective Differential Evolution (MODE): Propuesto por (Xue, Sanderson y Graves 2003). En esta versión se introduce un mecanismo basado en dominancia de Pareto para realizar la selección del mejor individuo que participará en la creación de la nueva generación.
- Nondominated Sorting Differential Evolution (NSDE): Propuesto por (Iorio y Li 2004), tiene un mecanismo exactamente igual al NSGA-II, sustituyendo los operadores cruzamiento y mutación, por los operadores propios de la evolución diferencial.
- Differential Evolution for Multi-Objective Optimization (DEMO): Propuesto por (Robic y Filipic 2005), tiene la particularidad de que los autores proponen un mecanismo de nueva generación-progenitores basado en dominancia de Pareto. El mecanismo de control de la población es similar al empleado en NSGA-II, truncando la población con criterios de distancia.

- Generalized Differential Evolution (GDE3): En la última versión de esta técnica se mejoran los problemas de lentitud de convergencia de las versiones anteriores, aumentando el tamaño de la población y empleando mecanismos parecidos a los empleados en NSGA-II.

4.3.7.1.3 Combinadas

En este último grupo se consideran aquellas aproximaciones que realizan una hibridación entre la ED y otras metaheurísticas de optimización. Algunas de las más interesantes son:

- Vector Evaluated Differential Evolution (VEDE): Esta técnica propuesta (Parsopoulos et al. 2004), está basada en VEGA con algunas modificaciones relacionadas con la ED.
- Differential Evolution for Multiobjective Optimization for Rough Sets (DEMORS): Es una hibridación de ε -MyDE con Rough Sets, propuesta por (Hernández-Díaz et al. 2006).
- ε -constraint Differential Evolution: Propuesta por (Landa-Becerra y Coello Coello 2006), hibrida la técnica de restricciones ε con la ED.

4.4 SIMULATED ANNEALING MULTIOBJETIVO - MOSA

En otra línea diferente podemos encontrar aquellos métodos que emplean como metaheurística de optimización un algoritmo basado en técnicas de recocido simulado (o *Simulated Annealing*). En las referencias (Smith 2006) y (Suman y Kumar 2006) se pueden encontrar estados del arte de que resumen con claridad, algunas de las propuestas más significativas que emplean técnicas de este tipo. Todas ellas se desarrollan a partir de finales de los 90 y hasta la actualidad, lo que pone de manifiesto que es un campo de la optimización multiobjetivo vigente, el mismo se ha actualizado con las últimas publicaciones que han aparecido en este campo.

El *Simulated Annealing*, en adelante SA, es una técnica compacta y robusta, que ha sido empleada en multitud de problemas de optimización mono-objetivo, incluyendo el FLP monoobjetivo en los que ha obtenido soluciones eficientes y con un coste computacional competitivo.

En este apartado se realizará una revisión de las diferentes variantes del algoritmo que han surgido en estos años para abordar problemas multiobjetivo y que se recogen en la Figura 4.4.1.

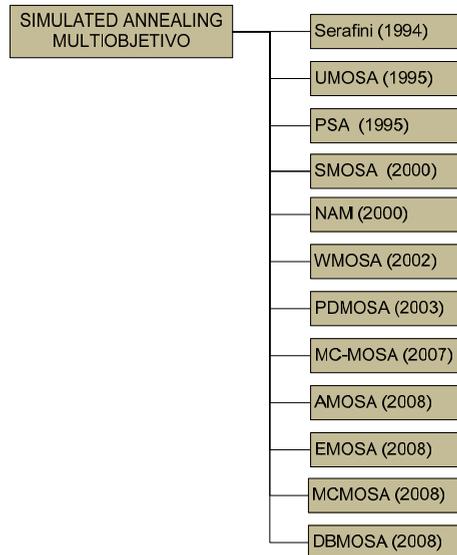


Figura 4.4.1 Técnicas de optimización multiobjetivo basadas en Simulated Annealing.

Existen diferentes formas de abordar el problema, pero prácticamente todas las técnicas que se comentan en la figura, se pueden dividir en 3 grandes vías, que se muestran gráficamente en la Figura 4.4.2.

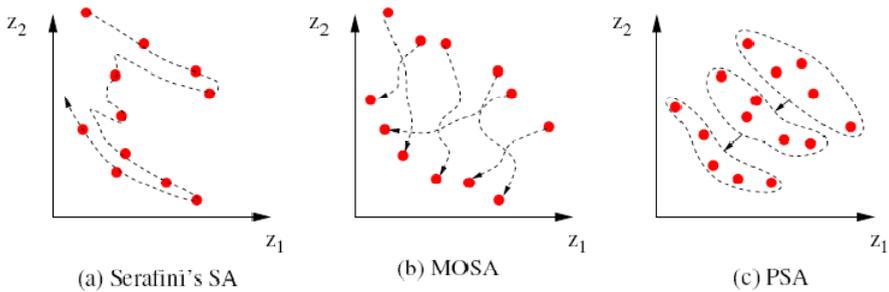


Figura 4.4.2 Tres vías diferentes de abordar el problema de optimización (Knowles y Corne 2004).

En la aproximación de Serafini (a), se parte de una única solución, que se va evolucionando, mediante una agregación de objetivos de forma que se barre el espacio de soluciones, mientras se va construyendo y evolucionando el conjunto de Pareto.

En la aproximación de Ulungu (b), se realiza el rearranque del algoritmo desde puntos aleatorios y cada iteración proporciona diferentes puntos de la frontera de Pareto.

Por último la aproximación de Czyzak (c) es poblacional, y esa población inicialmente aleatoria va evolucionando hasta definir la frontera del problema.

4.4.1 Los primeros pasos

La primera aplicación multiobjetivo de SA fue propuesta por Serafini en (Serafini 1985) y evolucionada en (Serafini 1992) y (Serafini 1994). El algoritmo de esta metodología es prácticamente igual que el mono-objetivo, pero utiliza una variante del criterio de aceptación de soluciones del algoritmo original. Se investigan varios criterios alternativos para aumentar la probabilidad de aceptación de soluciones no dominadas. Propone una regla especial dada por la combinación de varios criterios para concentrar la búsqueda exclusivamente en soluciones no dominadas, una estrategia similar se plantea en (Ulungu et al. 1999).

Serafini trabajó estas técnicas en el problema del viajante (TSP), aunque no presenta resultados comparados con otras técnicas de optimización, por tanto es difícil evaluar su idoneidad.

4.4.2 UMOSA (Método de Ulungu y Teghem)

En los problemas de optimización mono-objetivo abordados con una técnica de *Simulated Annealing*, la probabilidad de transición a una solución no óptima (un movimiento de empeoramiento) es única y puede obtenerse sin ambigüedad, algo que no ocurre en cuando se pasa a trabajar con más de un objetivo.

En este tipo de problema, cuando se hace un movimiento desde la posición actual hacia una nueva posición se pueden dar tres situaciones:

- *Que el movimiento produzca una mejora.* Siempre se acepta con una probabilidad 1.
- *Que se mejoren ciertos objetivos y que se empeoren otros.* En este caso no hay una solución dominante y se necesita una estrategia para discriminar entre ambas soluciones.
- *Existe un empeoramiento en todos los objetivos.* En este caso la solución, pese a no mejorar ninguno de los criterios, es aceptada con una determinada probabilidad de transición.

El algoritmo UMOSA (en gran parte de la bibliografía se referencia como MOSA, aunque se ha preferido denominarlo como UMOSA, para diferenciarlo de la línea general), se gestó en (Ulungu, Teghem y Fortemps 1995) y queda definido en (Ulungu et al. 1999). El mismo tiene en cuenta todas las situaciones de transición comentadas anteriormente, utilizando una estrategia denominada “escalarización de criterios” donde la probabilidad de transición tiene en cuenta la distancia existente la solución inicial y la solución generada.

Realiza una transformación escalar de las funciones multiobjetivo como una función mono-objetivo utilizando la técnica de sumas ponderadas, es decir, proyectar el espacio multi-dimensional en un espacio mono-dimensional, mediante una suma ponderada y normalizada. Cada movimiento se acepta con la siguiente probabilidad:

$$P = 1 \text{ si } \Delta f \leq 0$$

$$P = \exp\left(\frac{-\Delta f}{T}\right) \text{ si } \Delta f > 0 \quad (4.17)$$

Donde Δf se puede definir como:

$$\Delta f = f(\bar{x}_{j+1}) - f(\bar{x}_j), \quad f(\bar{x}_j) = \sum_{i=1}^m \lambda_i \cdot f_i(\bar{x}_j) \quad (4.18)$$

En esta expresión, λ es el vector de pesos y f es la función escalar mono-objetivo obtenida del producto escalar del vector funciones objetivo (f_i) por el vector de ponderaciones normalizado (λ). La función de normalización también da lugar a soluciones diferentes, hecho que se discute en las dos referencias mencionadas anteriormente, aunque la diferencia no es significativa y por ello se emplea la más sencilla.

El Algoritmo UMOSA

Los pasos básicos del algoritmo UMOSA para un problema que tiene m funciones objetivo y n variables de decisión es el siguiente:

1. Se genera aleatoriamente un conjunto de vectores de pesos normalizados $\lambda' = (\lambda'_i, i = 1, 2, \dots, m)$ con valores entre 0 y 1, tal que $\sum_{i=1}^m \lambda'_i = 1$.
2. Se genera aleatoriamente una solución inicial \bar{x}_0 , se evalúan las m funciones objetivo, aplicando, si ha lugar, las correspondientes penalizaciones, colocándose la solución inicial en el conjunto de Pareto (P).
3. Mediante un mecanismo de generación se obtiene una nueva solución \bar{x}_1 , en la vecindad de la solución inicial \bar{x}_0 , se evalúan las m funciones objetivo aplicándose, si es necesario, las funciones de penalización a las funciones objetivo correspondientes.
4. Se compara la solución \bar{x}_1 con las soluciones en el conjunto Pareto (P) y se actualiza si el movimiento produce una mejora.
5. Si \bar{x}_1 es aceptado entonces $\bar{x}_0 = \bar{x}_1$ e ir al paso 8.
6. Si no se ha aceptado la solución \bar{x}_1 , se acepta con una probabilidad: $P = \exp\left(\frac{-\Delta f}{T}\right)$, si la solución \bar{x}_1 es aceptada, entonces $\bar{x}_0 = \bar{x}_1$, ir al paso 8.
7. Si no se acepta la solución \bar{x}_1 , entonces $\bar{x}_0 = \bar{x}_0$ e ir al paso 8.
8. Periódicamente, rearrancar el algoritmo para diversificar la búsqueda.
9. Periódicamente reducir la temperatura.
10. Se repiten los pasos 3-9, hasta un número predefinido de iteraciones.
11. Se repiten los pasos 1-10 para cada vector de ponderación λ' .

4.4.3 PSA (Pareto Simulated Annealing, Czyzak)

Czyzak y Jaskiewicz trabajaron con la optimización multiobjetivo mediante SA, en los años 90 (Czyzak y Jaskiewicz 1996), (Czyzak y Jaskiewicz 1997) y (Czyzak y Jaskiewicz 1997) y finalmente presentaron un nuevo algoritmo, el PSA (*Pareto Simulated Annealing*) en (Czyzak y Jaskiewicz 1998). Este algoritmo combina un SA mono-objetivo con algoritmos genéticos para proporcionar soluciones eficientes generando una buena aproximación al conjunto de soluciones eficientes (o no dominadas) en un número de iteraciones relativamente corto.

PSA emplea el concepto de vecindad, de aceptación de nuevas soluciones con una cierta probabilidad y el esquema de enfriamiento del SA y el uso de una muestra poblacional de soluciones de los algoritmos genéticos, por tanto es un algoritmo annealing poblacional.

Se emplean funciones normalizadas basadas en probabilidades de aceptación de nuevas soluciones. En cada iteración del procedimiento, un conjunto de soluciones llamado "muestra generadora" controla los pesos de los objetivos empleados en la probabilidad de aceptación. Esta variación de pesos, asegura que se alcancen todo el espectro de soluciones eficientes. Se puede incrementar o disminuir la probabilidad de mejorar los valores de un objetivo en concreto controlando el peso del mismo. Cuanto mayor sea el peso asociado con el objetivo en cuestión menor será la probabilidad de aceptar movimientos que reduzcan el valor de este objetivo y mayor la probabilidad de mejorarlo.

El algoritmo PSA

1. Elegir una muestra generadora inicial de entre el conjunto de soluciones factibles, $X_0(\bar{x}_i) \in S$ y actualizar el conjunto de soluciones no dominadas (P) para cada solución del conjunto generador de soluciones ($\forall \bar{x}_i \in X_0$).

Para cada una de las soluciones (\bar{x}_i) de la muestra generadora X_0 :

2. Generar una solución aleatoria \bar{x}_i' , en la vecindad de la solución $\bar{x}_i \in X_0$, evaluando todos los objetivos. Si \bar{x}_i' es no dominada, incluirla en el conjunto de Pareto (P), actualizándolo.
3. Seleccionar la solución $\bar{x}_i'' \in X_0$, más cercana a \bar{x}_i no dominada por ella.
4. Si no existe \bar{x}_i'' o es la primera iteración, establecer unos pesos aleatorios normalizados que cumplan:

$$\forall i, \lambda_i \geq 0 \text{ y } \sum_{i=1}^m \lambda_i = 1 \quad (4.19)$$

5. Si existe \bar{x}_i'' , determinar los pesos para cada uno de los m objetivos:

$$\lambda_i = \begin{cases} \alpha \cdot \lambda_i^{x_i}, & f_i(\bar{x}_i) \geq f_i(\bar{x}_i'') \\ \lambda_i^{x_i} / \alpha, & f_i(\bar{x}_i) < f_i(\bar{x}_i'') \end{cases} \quad (4.20)$$

Donde: $\alpha > 1$ y los pesos deben ser normalizados de forma que $\sum_{i=1}^m \lambda_i = 1$.

6. Si la solución es dominada, aceptarla con una probabilidad de transición igual a:

$$P = \min \left(1, \sum_{i=1}^m \exp \left\{ \frac{-\Delta f_i}{T} \right\} \right) \quad (4.21)$$

Esta forma de determinar la transición a soluciones dominadas se conoce como regla SL, donde todos los objetivos son agregados con una suma ponderada. Si la solución \bar{x}_i'' es aceptada, tomarla como solución actual e ir al paso 9.

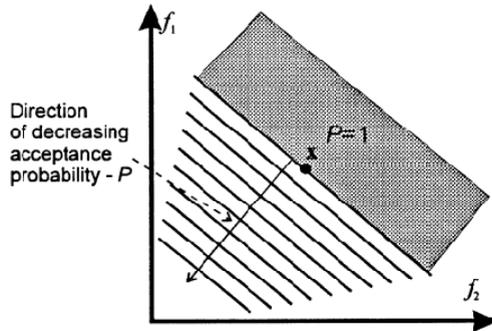


Figura 4.4.3 Ilustración gráfica de la regla SL (Czyzak y Jaskiewicz 1998).

7. Si la solución \bar{x}_i'' es no aceptada, mantener la solución inicial como la actual e ir al paso 9.
8. Reducir la temperatura periódicamente empleando un esquema *annealing* en función del problema a optimizar.
9. Repetir los pasos de 1–8, hasta un número predefinido de iteraciones.

Los autores comparan los resultados de su algoritmo con el UMOSA y con el propuesto por Serafini, aplicándolos sobre problemas test y midiendo las distancias a las soluciones de referencia.

4.4.4 SMOSA (Método de Suppapitnarm y Parks)

Otra técnica diferente se propone en (Suppapitnarm et al. 2000) donde los autores emplean el concepto de archivar las soluciones óptimas de Pareto para resolver problemas multiobjetivo con SA. El método está basado en el propuesto en (Engrand 1997) y permite la búsqueda y el re-arranque del algoritmo en sucesivas iteraciones desde soluciones archivadas de una determinada región de la frontera de Pareto. Esta estrategia se conoce como “retorno a la base”. Los autores proponen una formulación para la probabilidad de transición basada en un esquema annealing con múltiples temperaturas (una por objetivo), algo novedoso en este campo. No emplean una función objetivo compuesta, es decir, no se agregan los objetivos en el cálculo de la probabilidad de transición y los cambios en cada objetivo se comparan antes de archivar la solución, esto asegura la posibilidad de transición a soluciones no-dominadas.

Los pasos básicos del algoritmo SMOSA para un problema con m funciones objetivo y n variables de decisión son los siguientes.

El algoritmo SMOSA

1. Iniciar con una solución inicial \bar{x}_0 generada aleatoriamente, evaluando todas las funciones objetivo y agregando esta primera solución al conjunto de soluciones de Pareto (P).
2. Mediante un mecanismo de generación se obtiene una nueva solución \bar{x}_1 en la vecindad de la solución inicial \bar{x}_0 .
3. Se compara la solución generada \bar{x}_1 con todas las soluciones del conjunto de Pareto (P) y se actualiza el mismo si es necesario.
4. Si \bar{x}_1 entra en (P), entonces se hace $\bar{x}_0 = \bar{x}_1$ e ir al paso 7.
5. Si la solución \bar{x}_1 no entra en (P), se hace $\bar{x}_0 = \bar{x}_1$ con una probabilidad:

$$P = \left(1, \prod_{i=1}^m \exp \left\{ \frac{-\Delta f_i}{T_i} \right\} \right) \quad (4.22)$$

Dónde: $\Delta f_i = (f_i(\bar{x}_1) - f_i(\bar{x}_0))$

6. Si \bar{x}_1 no es aceptado, se retiene la última solución $\bar{x}_0 = \bar{x}_0$ y va al paso 7.
7. Periódicamente se reinicia el algoritmo con una solución seleccionada aleatoriamente del conjunto Pareto (P) (los autores recomiendan que esté sesgada en los extremos de la frontera). Esta estrategia la denominan “retorno a la base”.
8. Periódicamente se reduce la temperatura empleando el esquema de enfriamiento apropiado para el problema a optimizar.
9. Repite los pasos 2 al 8, hasta un número predeterminado de iteraciones.

4.4.5 NAM y PARK

La aproximación al problema MOSA realizado por (Nam y Park 2000) es una de las más interesantes. En este algoritmo, se estudia la dominancia relativa entre la solución actual (\vec{x}_0) y propuesta (\vec{x}_1), teniendo los siguientes casos:

a) Solución propuesta domina a actual ($\vec{x}_1 \prec \vec{x}_0$) o son mutuamente no dominadas.

Si la solución propuesta domina a la actual, la misma entra a formar parte del conjunto de Pareto (P), eliminando aquellas a las que domina, y se toma como solución actual, lo mismo ocurre en el caso en el que ambas soluciones son mutuamente no dominadas (situación que se muestra en la Figura 4.4.4).

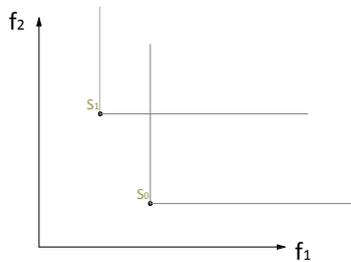


Figura 4.4.4 Soluciones mutuamente no dominadas.

b) Solución propuesta dominada por la actual ($\vec{x}_0 \prec \vec{x}_1$).

Los autores modifican la regla de transición de tal manera que si la solución propuesta es dominada por la actual es aceptada con una probabilidad de transición:

$$P = \min \left(1, \exp \left\{ \frac{-\Delta f_i}{T_i} \right\} \right) \quad (4.23)$$

Donde $\Delta f_i = (f_i(\vec{x}_1) - f_i(\vec{x}_0))$ y $f_i(\vec{x}_1) = \sum_{i=1}^m \omega_i \cdot f_i(\vec{x}_1)$

Esto promueve la exploración extensiva del espacio de búsqueda y la posibilidad de escapar de mínimos locales, aunque a medida que el número de objetivos crece, también lo hace la proporción de movimientos que son aceptados incondicionalmente. Esto limita el comportamiento del algoritmo haciéndolo prácticamente un “random walk” a través del espacio de soluciones en problemas con gran número de objetivos.

Los autores proponen hasta seis esquemas para realizar el cálculo del incremento de coste Δf_i , a emplear en (4.23):

1. *Criterio de mínimo coste*

Se considera el mínimo incremento de coste entre soluciones obtenido para todas las funciones objetivo:

$$\Delta f_i = \min_i (f_i(\bar{x}_1) - f_i(\bar{x}_0)) \quad (4.24)$$

2. *Criterio de máximo coste*

Se emplea el máximo incremento de coste entre soluciones obtenido para todas las funciones objetivo:

$$\Delta f_i = \max_i (f_i(\bar{x}_1) - f_i(\bar{x}_0)) \quad (4.25)$$

3. *Criterio de coste aleatorio*

Se obtiene multiplicando el incremento de coste entre soluciones de cada una de las **m** funciones objetivo por una variable aleatoria α obtenida de una función uniformemente distribuida.

$$\Delta f_i = \sum_{i=1}^m \alpha_i \cdot (f_i(\bar{x}_1) - f_i(\bar{x}_0)) \quad (4.26)$$

4. *Criterio de coste propio*

En este esquema únicamente tienen en cuenta los costes de la solución propuesta para cada una de las funciones objetivo.

$$\Delta f_i = \sum_{i=1}^m f_i(\bar{x}_1) \quad (4.27)$$

5. *Criterio de coste medio*

Proponen emplear la media de los incrementos de las **m** funciones objetivo:

$$\Delta f_i = \frac{\sum_{j=1}^m f_j(\bar{x}_1) - f_j(\bar{x}_0)}{m} \quad (4.28)$$

6. *Criterio de coste fijo*

Se utiliza un valor constante y de valor preestablecido.

Los autores también proponen emplear un esquema de enfriamiento del tipo geométrico, con la siguiente expresión:

$$T_j = \alpha^j \cdot T_0 \quad (4.29)$$

Donde: α es un ratio de enfriamiento comprendido entre 0 y 1.

Tras realizar ensayos para un problema bicriterio, resuelven que el mejor esquema es el criterio de coste medio (5).

Posteriormente los mismos autores realizan una nueva publicación con este algoritmo en (Nam y Park 2002), comparándolos resultados obtenidos con diferentes variantes de MOEAs.

4.4.6 WMOSA (Weighted based Multi-Objective Simulated Annealing)

Propuesto en (Suman 2002) y (Suman 2003), incluye las restricciones del problema en el algoritmo principal, empleando un vector de ponderación en el criterio de aceptación.

El vector de pesos W (u -dimensional), depende del número de restricciones incumplidas por el vector de soluciones respecto al total de restricciones, y sus valores se obtienen de la siguiente forma:

$$W_j = \frac{n^{\circ} \text{ de restricciones satisfechas por } S_j}{n^{\circ} \text{ de restricciones del vector de soluciones}} \quad (4.30)$$

Los pasos básicos del algoritmo WMOSA para un problema con u funciones objetivo y n variables de decisión son los siguientes:

El algoritmo WMOSA

1. Inicia con una solución inicial \bar{x}_0 generada aleatoriamente, se evalúan todas las funciones objetivo y se agrega al conjunto de soluciones Pareto (P).
2. Mediante un mecanismo de generación se obtiene una nueva solución \bar{x}_1 en la vecindad de la solución inicial \bar{x}_0 .
3. Se compara la solución generada \bar{x}_1 con todas las soluciones en el conjunto Pareto y se actualiza (P), si es necesario.
4. Si S_1 entra al conjunto de Pareto, entonces $\bar{x}_0 = \bar{x}_1$ e ir al paso 7.
5. Si la solución \bar{x}_1 no es Pareto, se hace $\bar{x}_0 = \bar{x}_1$ con una probabilidad:

$$P = \min \left(1, \exp \left\{ \frac{-\Delta f}{T} \right\} \right) \quad (4.31)$$

Dónde: $\Delta f = W(\bar{x}_1) \cdot f_i(\bar{x}_1) - W(\bar{x}_0) \cdot f_i(\bar{x}_0)$

Si la solución \bar{x}_1 es aceptada, hacer $\bar{x}_0 = \bar{x}_1$ e ir al paso 7.

6. Si \bar{x}_1 no es aceptado, se retiene la última solución $\bar{x}_0 = \bar{x}_0$ y va al paso 7.
7. Periódicamente, reinicia con una selección aleatoria del conjunto Pareto.
8. Periódicamente reduce la temperatura empleando el esquema de enfriamiento de SA más apropiado para el problema a optimizar.
9. Repetir los pasos 2 al 8, hasta un número predeterminado de iteraciones.

Los autores comparan resultados con los obtenidos mediante SMOSA, justificando que con WMOSA se obtienen soluciones de una mayor calidad que las obtenidas por aquel.

4.4.7 PDMOSA (Pareto Dominated Multi-Objective Simulated Annealing)

Fue propuesto en (Suman 2004) y (Suman 2005) y tiene una filosofía de funcionamiento muy similar al SPEA de (Zitzler y Thiele 1998), pues ambos emplean el concepto de valor de ajuste de una solución, aunque el PDMOSA emplea el SA en vez de algoritmos genéticos como metaheurística de optimización.

La diferencia principal entre PDMOSA y el resto de aproximaciones mediante SA reside en que esta metodología no necesita emplear el valor de la función objetivo en el criterio de aceptación, sino que emplea un valor de ajuste, que puede ser obtenido del conjunto de Pareto (conteniendo tanto las soluciones factibles como las no factibles).

El ajuste de una solución generada f'_{i,\bar{x}_i} se define como $1 +$ el número de soluciones de (P) que la dominan. Definido de esta forma, un valor menor del ajuste indica una mejor solución, con un mínimo de 1 si la solución generada \bar{x}_i entra a formar parte del conjunto de Pareto.

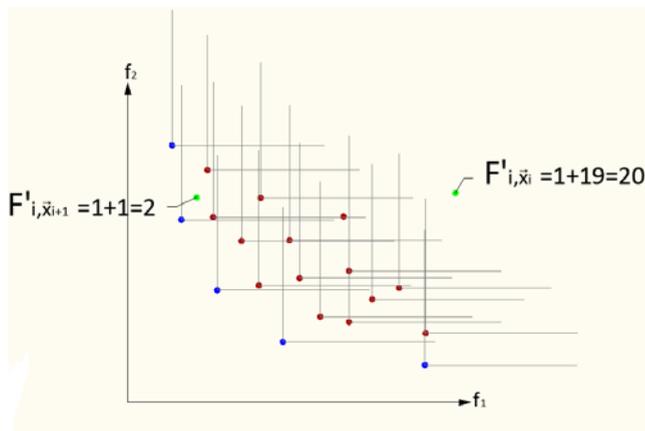


Figura 4.4.5 Cálculo de los ajustes según PDMOSA.

Esto simplifica el cálculo de la fase de obtención de las probabilidades y orienta la búsqueda hacia el espacio de las soluciones no dominadas.

Los pasos básicos del algoritmo PDMOSA para un problema con m funciones objetivo y n variables de decisión son los siguientes:

El algoritmo PDMOSA

1. Inicia con una solución inicial \bar{x}_0 generada aleatoriamente, se evalúan todas las funciones objetivo y se agrega al conjunto de soluciones Pareto (P).
2. Mediante un mecanismo de generación se obtiene una nueva solución \bar{x}_1 en la vecindad de la solución inicial \bar{x}_0 .
3. Se compara la solución generada \bar{x}_1 con todas las soluciones en el conjunto (P) (tanto las factibles como las no factibles) y se actualiza (P), si es necesario. Este conjunto se emplea para el cálculo del ajuste de la solución.
4. Aceptar la solución \bar{x}_1 generada como solución actual \bar{x}_0 con una determinada probabilidad dada por:

$$P = \min\left(1, \exp\left\{\frac{-\Delta f^i}{T}\right\}\right) \quad (4.32)$$

Dónde, $\Delta f^i = F'_{i-1, \bar{x}_0} - F'_{i, \bar{x}_1}$ con F'_{i, \bar{x}_1} como el valor de ajuste de dominación de Pareto de la solución generada en la iteración i , y F'_{i-1, \bar{x}_0} como el valor de ajuste de dominación de Pareto de la solución actual en la iteración $i-1$.

5. Si \bar{x}_1 no es aceptado, se retiene la última solución $\bar{x}_0 = \bar{x}_0$ y va al paso 6.
6. Periódicamente, reinicia con una solución seleccionada aleatoriamente del conjunto de Pareto (P).
7. Periódicamente reduce la temperatura empleando el esquema de SA apropiado para el problema.
8. Repite los pasos 2 al 7, un número predeterminado de iteraciones.

El autor aplica el algoritmo PDMOSA a un problema tipo, junto con otros algoritmos (UMOSA, PSA, y WMOSA) con los que se comparan los resultados, concluyendo el autor que este algoritmo genera soluciones diversificadas y funciona bien con problemas continuos y de pocas variables.

4.4.8 MC-MOSA (Multi Cooling Multi-Objective Simulated Annealing)

El algoritmo propuesto por (Tekinalp y Karsli 2007), se caracteriza por utilizar valores de ajuste, o FF (*Fitness Function*) en el cálculo de las probabilidades de transición a soluciones dominadas en el proceso de optimización, los autores proponen un algoritmo poblacional, como en PSA. Otra característica de este algoritmo es que utiliza temperaturas de enfriamiento (T_j) individuales para cada uno de los m objetivos, al igual que hacían (Nam y Park 2000).

El algoritmo MC-MOSA

1. Generar aleatoriamente una solución inicial \bar{x}_0 , y calcular el vector de temperaturas iniciales T_0
2. Generar un vector de números aleatorios $V^k (0 \leq V^k \leq 1)$ de una distribución uniforme.
3. Evaluar la probabilidad de transición, mediante las expresiones:

$$P = \min \left(1, \max \left[\frac{\Delta F_i^k}{T_i^k} \right] \right) \quad (4.33)$$

Donde: $\Delta F_i^k = F_i(\bar{x}_0^k) - F_i(\bar{x}_1^k) \quad : \quad i=1, \dots, m, y$

F_i es un conjunto de de funciones de ajuste.

4. Aceptar la solución generada, \bar{x}_1 , para la que se ha calculado la probabilidad de transición (4.33) de la siguiente forma:

$$\bar{x}_0^{k+1} = \begin{cases} \bar{x}_1^k & \text{si } V^k \in (0, Pr) \\ \bar{x}_0^k & \text{en otro caso} \end{cases} \quad (4.34)$$

5. Si la probabilidad de transición es 1:
 - Archivar la solución generada $\bar{x}_0^{k+1} = \bar{x}_1^k$ en las soluciones del conjunto de Pareto (P).
 - Archivar también los valores de los objetivos que mejoran los obtenidos en iteraciones anteriores, para poder calcular posteriormente los valores de las funciones de ajuste.
 - Actualizar la temperatura del *annealing*.
6. Incrementar el contador y volver a ejecutar desde 1.

Los autores aplican el algoritmo a problemas estructurales y aeroespaciales.

4.4.9 AMOSA

En (Bandyopadhyay et al. 2008) se encuentra una de las últimas variantes de los algoritmos SA para la optimización multiobjetivo, el denominado AMOSA (*Archived MultiObjective Simulated Annealing*), que está basado en el concepto de Dominancia de Pareto, al igual que PDMOSA.

En AMOSA, los autores emplean una expresión (4.35) para el cálculo de la probabilidad de transición ligeramente distinta a los algoritmos anteriores, con la finalidad de que la misma quede acotada entre 0 y 1.

$$P = \frac{1}{1 + \exp\left\{\frac{-\Delta f^i}{T}\right\}} \quad (4.35)$$

También es destacable, debido a la forma en la que se aborda el problema de optimización, la aparición de un *Archivo*, donde se guardan todas las soluciones que son No dominadas, y que conforman el conjunto de Pareto (P).

Los pasos fundamentales del algoritmo AMOSA, para el caso de m objetivos son los siguientes:

El algoritmo AMOSA

1. En las fases iniciales del algoritmo, se inicializa *Archivo* generando una serie de soluciones no dominadas, mediante una serie de lanzamientos del algoritmo, limitando el tamaño del *Archivo* en el rango $[1, HL]$.
2. En segundo lugar se realiza un "*clustering*" de las soluciones existentes en el *Archivo*, de forma similar al que se realiza en SPEA, para reforzar la diversidad de las soluciones no dominadas. en este caso se permite que el tamaño del mismo se vaya a $[1, SL]$, con $SL > HL$.
3. Un tercer detalle importante de este algoritmo es el empleo de una medida como la *cantidad de dominación* entre dos soluciones a y b , que queda definido por:

$$\Delta dom_{a,b} = \prod_{j=1, f_j(a) \neq f_j(b)}^m \left(|f_j(a) - f_j(b)| / R_j \right) \quad (4.36)$$

en esta expresión, j es cada uno de los m objetivos, y R_j es el rango del objetivo.

4. Se fija una temperatura inicial ($T = T_{max}$), se selecciona un punto aleatorio de *Archivo* (\bar{x}_0) y se genera una solución propuesta en la vecindad del mismo (\bar{x}_1), estudiando las diferentes situaciones que se pueden dar:

- a) La solución actual domina a la propuesta $\bar{x}_0 \prec \bar{x}_1$ y k puntos de Archivo ($k \geq 0$) también lo hacen.

En esta situación se acepta la solución propuesta S_1 como la solución actual con una probabilidad:

$$P = \frac{1}{1 + \exp(\Delta dom_{avg} * T)} \quad (4.37)$$

Donde la cantidad de dominación media se define como:

$$\Delta dom_{avg} = \frac{\left(\left(\sum_{i=1}^k \Delta dom_{i, S_1} \right) + \left(\sum_{i=1}^k \Delta dom_{S_0, S_1} \right) \right)}{k + 1} \quad (4.38)$$

- b) Las soluciones \bar{x}_0 y \bar{x}_1 son mutuamente no dominadas.

A su vez pueden darse dos situaciones, que se resumen a continuación.

El nuevo punto, \bar{x}_1 no es dominado por ninguna de las k soluciones del Archivo, en cuyo caso entra a formar parte de él. Con esta entrada es posible que se produzcan dos casos más, que domine a alguna solución del Archivo, en cuyo caso hay que eliminar las soluciones dominadas del mismo o que no lo haga, y se añada directamente

El nuevo punto, \bar{x}_1 es dominado por alguna/s de la/s soluciones del Archivo, en cuyo caso se aplica la ecuación (4.38).

- c) La solución propuesta domina a la actual $\bar{x}_1 \prec \bar{x}_0$.

A su vez, se pueden dar dos situaciones, que la solución propuesta sea dominada por alguno de los k puntos del Archivo, en cuyo caso se acepta con una probabilidad calculada según (4.38), y que no sea dominada, en cuyo caso entra a formar parte del Archivo, debiendo comprobar, como en el caso anterior si entra dominando algún otro punto del mismo (en cuyo caso se eliminan) o se añaden simplemente al Archivo.

Los autores aplican su algoritmo sobre seis problemas de tres objetivos de referencia (DTLZ1-DTLZ6), comparándolos con los resultados obtenidos mediante algoritmos como NSGA-II y PAES.

4.4.10 EMOSA

(Li y Landa-Silva 2008) proponen una metaheurística combinada entre un SA y algoritmos genéticos, que trata de aprovechar las virtudes de ambas técnicas de optimización. Por una parte explota la búsqueda local mediante SA y la evolucionaria mediante algoritmos genéticos.

Existen diferencias significativas en la forma de determinar si la solución propuesta (\bar{x}_1) pasa a ser la solución actual (\bar{x}_0), pues no todas las soluciones aceptadas pasan a ser la base para la siguiente etapa.

Los pasos fundamentales del algoritmo son los siguientes:

El algoritmo EMOSA

1. Inicialización

Generar aleatoriamente una población de soluciones iniciales de tamaño p , así como un vector de pesos normalizados uniformemente distribuidos.

Conformar un archivo con las soluciones no dominadas (NDS) de la solución inicial de tamaño p . Fijar la temperatura $T=T_0$.

2. Evolución de la población.

Para cada uno de los p miembros de la población (\bar{x}_0):

- Generar una solución \bar{x}_1 en la vecindad de \bar{x}_0 .
- Actualizar NDS con la solución \bar{x}_1 , si $\bar{x}_1 \prec \bar{x}_0$.
- Hacer la solución \bar{x}_1 la solución actual ($\bar{x}_0 = \bar{x}_1$) con una probabilidad P (similar a la empleada en (4.32)).
- Competición entre los miembros de la población activa para determinar si se realiza la transición a cualquier otra solución de la misma.

3. Cambio de Temperatura

El esquema de enfriamiento se rige mediante la siguiente expresión:

$$T_{i+1} = T_i - \alpha \quad (4.39)$$

Si la $T < T_c$ se va a 4, sino a 5.

4. Adaptación de la dirección de búsqueda

Encontrar la solución no dominada (del conjunto NDS) más cercana al punto actual, para establecer la dirección de búsqueda hacia ella, mediante la configuración de los pesos correspondiente.

5. Criterio de Parada

El algoritmo se para cuando $T < T_{\min}$, sino ir al paso 2.

Los autores aplican el algoritmo al problema del viajante (TSP) bicriterio de 50 ciudades, comparando los resultados con los algoritmos de Serafini, UMOSA, PSA, y PAES.

4.4.11 MCMOSA

En (Haidine y Lehnert 2008) se puede encontrar una técnica basada en la dominancia de Pareto, donde la solución propuesta se compara con todas las soluciones del conjunto de no dominadas, y es (en el caso de que la propuesta sea dominada) el numero de soluciones que dominan a la actual el parámetro del que depende la probabilidad de transición.

Una aproximación muy parecida, y coetánea se desarrolla con más profundidad en el siguiente punto. Una característica singular de esta propuesta es el empleo de una técnica de enfriamiento *re-annealing*, en la que se realizan calentamientos periódicos en la fase de enfriamiento. La temperatura es común para todos los objetivos.

4.4.12 DBMOSA

La última publicación en ésta línea de la optimización multiobjetivo es el *Dominance Based MOSA*, publicado en (Smith, Fieldsend et al. 2008) .

Los autores emplean una medida diferente para determinar la probabilidad de transición a soluciones dominadas:

$$P = \min(1, \exp(-\delta E(\bar{x}_1, \bar{x}_0) / T)) \quad (4.40)$$

en ella se utiliza la *diferencia de energía* ($\delta E(\bar{x}_1, \bar{x}_0)$) entre la solución actual (\bar{x}_0) y la propuesta (\bar{x}_1), y que se calcula de la siguiente forma:

$$\delta E(\bar{x}_1, \bar{x}_0) = \frac{1}{F} (F_{\bar{x}_1} - F_{\bar{x}_0}) \quad (4.41)$$

Donde F es el conjunto de puntos no dominados en el instante del cálculo de la diferencia de energía (en la Figura 4.4.6, adquiere el valor 10) y los valores $F_{\bar{x}_0}$ y $F_{\bar{x}_1}$ son las cantidades de puntos de F que dominan \bar{x}_0 y \bar{x}_1 respectivamente (en la Figura 4.4.6, adquieren los valores 3 y 1, respectivamente).

Así la diferencia de cantidad de energía calculada según la ecuación (4.41), para el ejemplo es $\delta E(\bar{x}_1, \bar{x}_0) = \frac{1}{10}(1-3) = 0.2$

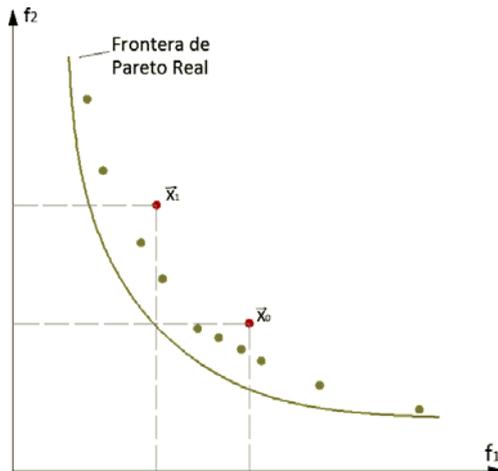


Figura 4.4.6 Ejemplo del cálculo de δE

Si F es un número demasiado pequeño, los autores proponen una metodología para obtener más puntos con los que engrosar F para que el proceso de optimización sea más efectivo (*sampling points from the attainment surface*).

El algoritmo es similar en la forma de trabajo a AMOSA, aunque la variable de decisión para determinar la transición a una solución dominada es el incremento de energía entre los puntos actual y propuesto, calculado de la forma comentada con anterioridad. También incorpora la actualización constante de la frontera, eliminando los puntos dominados y manteniendo aquellos que son mutuamente no dominados.

Los pasos básicos del algoritmo son los siguientes:

El algoritmo DBMOSA

1. Inicializar el archivo F en el que se almacenaran las soluciones no dominadas, estableciendo su tamaño mínimo (S). Fijar los escalones de temperatura para el *annealing*, y obtener una solución inicial (\bar{x}_0) en F.
2. Obtener una solución en la vecindad de la solución actual (\bar{x}_1).
3. Si $|F| < S$ se inicia la rutina para generar más puntos de F (*sampling points from the attainment surface*). En caso contrario se añaden \bar{x}_0 y \bar{x}_1 a F.
4. Se acepta \bar{x}_1 calculando la probabilidad de transición según la expresión (4.40).
5. Se inicia un proceso de depuración de F eliminando los puntos que sean dominados por otros.
6. Una vez repetida k veces la rutina se baja un escalón de temperatura según el esquema de enfriamiento:

$$T_{k+1} = T_k - \alpha \quad (4.42)$$

Los autores aplican el algoritmo a los problemas tipo (DTLZ1-DTLZ6), comparando los resultados con los obtenidos mediante NSGA-II.

5 PLANTEAMIENTO MULTIOBJETIVO DEL PROBLEMA DE DISTRIBUCIÓN EN PLANTA

Tal y como se introdujo en el capítulo 1 del presente trabajo, Muther en 1968 establece una metodología organizada y sistemática (SLP) para resolver el problema de la Distribución en Planta. En ella hace mención expresa al carácter multicriterio del problema en dos fases claramente diferenciadas (Muther 1968) :

- a) La tabla relacional de actividades (TRA) es fruto del estudio de las relaciones entre actividades, como consecuencia de múltiples factores, y se constituye como punto de partida en la síntesis de alternativas (en ella queda patente el marcado carácter multiobjetivo del problema).
- b) La evaluación y selección de alternativas, por otra parte, se debe realizar mediante alguna metodología multicriterio.

Tompkins y White, por su parte, insisten en la necesidad de reconocer la naturaleza multicriterio del problema de la Distribución en Planta:

*"Given certain interactions that occur among the departments, generally speaking, the facility layout problem is concerned with determining the **most efficient** arrangement of the departments subject to constraints imposed by the site plan, the building, the departmental area/service requirements, and the decision maker"*

(Tompkins y White 1984)

Desde la formulación inicial del problema de localización de plantas industriales establecido en (Koopmans y Beckman 1957) hasta el año 1979 fueron muchos los intentos por resolver el problema de la Distribución en Planta. Cada publicación establecía nuevas estrategias en los procedimientos de construcción y/o mejora y diferentes formas de evaluar la calidad de cada una de las soluciones obtenidas, pero siempre desde un enfoque monobjetivo, que trataba, en la mayor parte de los casos, de minimizar el coste derivado del movimiento de los materiales.

En este año, aparece una publicación (Rosenblatt 1979) en la que el autor plantea una primera propuesta para combinar dos criterios a la hora de obtener la distribución más eficiente, es por tanto el primer intento de abordar el problema con una formulación claramente multiobjetivo (anteriormente Muther, en la resolución del problema mediante teoría de grafos ya había introducido parcialmente algunos aspectos multiobjetivo).

En el estado del arte previo a la metodología propuesta, el autor resume las dos grandes corrientes de trabajo existente en ese momento, diferenciadas por la naturaleza de la función objetivo empleada y establece un nuevo camino para abordar el FLP como un problema de naturaleza multiobjetivo.

1. *Función objetivo establecida mediante criterios cuantitativos*

Donde quedan enmarcadas técnicas como: *Craft* (Armour y Buffa 1963), *Gilmore* (Gilmore 1962), *Lawler* (Lawler 1963), *Hillier* (Hillier 1963) (Hillier y Connors 1966), *Frat* (Khalil 1973)..., en las que la resolución del problema se centra en el objetivo de minimizar los costes relacionales derivados de un único criterio, el transporte de materiales entre actividades (en adelante MHC, de *Material Handling Cost*). Son por tanto técnicas **cuantitativas monobjetivo**.

"The cost of moving material from one manufacturing area to another is a complete loss insofar as its effect upon the value of the product is concerned. For this reason it should be considered a manufacturing evil that must be completely eliminated or reduced to an absolute minimum"

(Cameron 1952)

En las distribuciones así obtenidas, las actividades quedan ubicadas en función de la secuencia de operaciones desarrolladas en el proceso productivo. El Recorrido de los Productos (expresado a través del Diagrama de Recorrido Sencillo, Diagrama Multiproducto o la Tabla Matricial) determina la distribución final.

Uno de los mayores inconvenientes que presenta este planteamiento es asumir que el coste relacional del sistema es directamente proporcional a la distancia recorrida por los productos. Sin considerar, por tanto, los costes relacionales que pudieran derivarse de la adyacencia o no adyacencia entre actividades por otra serie de motivos diversos (molestias ocasionadas por niveles sonoros excesivos, malos olores, seguridad en las plantas industriales, riesgos de incendio, explosión, etc.), primando los principios de circulación y mínima distancia sobre los de seguridad y confort, integración de conjunto, flexibilidad y espacio cúbico.

Este planteamiento no permite la integración de los Medios Auxiliares de Producción (Servicios Auxiliares para la Producción y Servicios para el Personal), puesto que las intensidades relacionales existentes entre éstos y los Medios Directos de Producción no se pueden expresar a través del Recorrido de los Productos.

Además, en ciertas plantas el Recorrido de los Productos es relativamente poco importante o incluso irrelevante, al apenas existir circulación de materiales, por lo que no es de esperar resultados adecuados bajo este tipo de planteamientos.

2. Función objetivo establecida mediante criterios cualitativos

Donde destacan procedimientos como *Aldep* (Seehof y Evans 1967) y *Corelap* (Lee y Moore 1967), basados en la minimización de los costes relacionales derivados de criterios cualitativos (establecidos mediante intensidades relacionales de la Tabla Relacional de Actividades). Son técnicas ***cualitativas monobjetivo***.

Estos métodos presentan un gran inconveniente: la imprecisión y la tendencia hacia la subjetividad en la forma de valorar las relaciones entre actividades.

Proponen, como punto de partida, la construcción de la Tabla Relacional de Actividades (Muther 1968) para evaluar la necesidad de proximidad entre pares de actividades bajo diferentes puntos de vista. Esta Tabla Relacional de Actividades, así construida, obedece a un planteamiento multicriterio del problema.

"One of the real difficulties in developing and using these multiple criteria models is the natural vagueness associated with the inputs to the model",

(Raoot y Rakshit 1993)

Con lo cual, la necesidad de proximidad entre actividades, y por tanto la Distribución en Planta, debe ser estudiada en función de la intensidad relacional existente entre las actividades como consecuencia de múltiples criterios.

Rosenblatt insiste en su publicación en la necesidad de estudiar el problema atendiendo a más de un criterio, en concreto uno cuantitativo y otro cualitativo, estableciendo una serie de soluciones que sean Eficientes, no óptimas.

Por otra parte, a la hora de planificar una Distribución en Planta puede ser muy interesante integrar en la formulación aspectos relativos a la entrada en funcionamiento del sistema productivo que se desea implantar, tener en cuenta aspectos relativos a la forma de las actividades que conforman el mismo, o la forma global de la planta. En otras situaciones puede ser muy recomendable incorporar a la fase de diseño aspectos como la seguridad de los operarios, los ruidos generados...tal y como se muestra en la Figura 4.40.1.

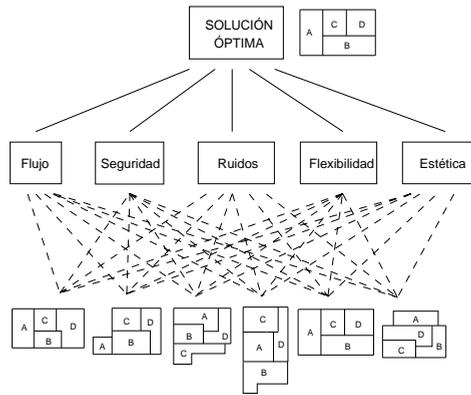


Figura 4.40.1 Naturaleza multicriterio del problema de la Distribución en Planta (Santamarina 1995).

El problema de distribución en planta es un problema de optimización que ha sido objeto de numerosas publicaciones en revistas internacionales, hasta el año 2006 cerca de 2000 (Sangwan y Kodali 2006). Este año se cumple el 30º aniversario de la publicación seminal de Rosenblatt y desde entonces únicamente en 40 artículos el problema es abordado desde una perspectiva y formulación multiobjetivo.

Entre estas publicaciones, podemos encontrar dos estados del arte:

- (Waghodekar y Sahu 1986), es una revisión que se produce en un momento en el que únicamente se habían producido 8 publicaciones en este campo, que aun estaba poco explorado. Los autores aportan una primera clasificación de las publicaciones hasta ese momento (ver Figura 5.0.2) en la que incluye técnicas como el MUCFAL de (Sayin 1981) y las técnicas MFLAP que propondrán los autores posteriormente en (Waghodekar y Sahu 1986) y una segunda la MFLAPSA que no se llegaría a publicar. Asimismo se realiza una descripción de los objetivos que se pueden emplear en la formulación del problema.

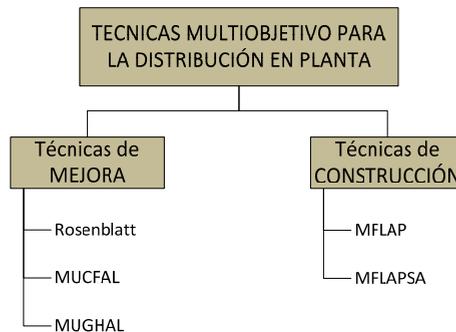


Figura 5.0.2 Clasificación de (Waghodekar y Sahu 1986)

- (Matai y Singh 2008), es una publicación en un congreso en la que se repasa una parte de las publicaciones realizadas en el campo, haciendo especial hincapié a la línea de trabajo de (Chen y Sha 2005), que es la misma que emplearán los autores en una publicación posterior. Cita los artículos más importantes en el campo, pero deja de lado muchas de las aportaciones realizadas en los últimos años.

Es por tanto necesario realizar un estado del arte minucioso y más actual en este campo para poder situar la metodología propuesta en el mismo de una manera precisa y marcar posibles líneas de investigación. Veamos cual ha sido la evolución temporal y algunas características de las publicaciones del FLP multiobjetivo.

El número de publicaciones en revistas internacionales en los 30 años de vigencia del problema ha sido constante y podemos asegurar que en los últimos años se ha visto incrementado, después de una época en la que no aparecieron apenas nuevas líneas de investigación en el campo.

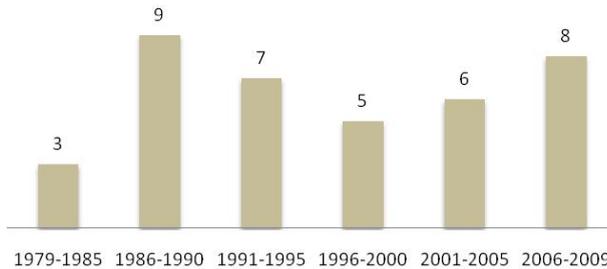


Figura 5.0.3 Publicaciones del problema FLP multiobjetivo en revistas internacionales.

En el presente capítulo se realiza una revisión de las publicaciones atendiendo a dos clasificaciones existentes, debidas a Waghodekar y Malakooti para pasar después a proponer una nueva clasificación, en la que se encuadrarán todas las publicaciones, haciendo un pequeño resumen y remarcando las características de cada una de ellas.

5.1 CLASIFICACIÓN DE LAS TÉCNICAS MULTI OBJETIVO APLICADAS AL PROBLEMA DE DISTRIBUCIÓN EN PLANTA

Tal y como se ha comentado con anterioridad, el problema de distribución en planta es claramente un problema multiobjetivo, pues se deben tener en cuenta tanto los objetivos cualitativos como los cuantitativos.

Desde el artículo seminal de Rosenblatt, han sido muchos los autores que se han aproximado al problema desde diferentes ámbitos, e introduciendo la naturaleza multicriterio en una fase diferente de la resolución del problema.

En la bibliografía existente podemos encontrar dos clasificaciones de estas técnicas atendiendo a diferentes criterios, que pasamos a comentar, para pasar después a proponer una nueva clasificación de las mismas:

5.1.1 Clasificación de Waghodekar y Sahu

En (Waghodekar y Sahu 1986) y (Santamarina 1995) podemos encontrar una primera clasificación de las técnicas multiobjetivo aplicadas al problema de distribución en planta, que tiene en cuenta el momento del proceso de optimización en el que se tiene en cuenta el carácter multicriterio del problema:



Figura 5.1.1 Clasificación de Waghodekar y Sahu.

De todas las referencias del problema encontradas en la bibliografía, la distribución de las mismas según esta clasificación es la que se muestra en la Figura 5.1.2, destacando el hecho de que la gran mayoría de referencias se pueden enmarcar dentro de técnicas de mejora.

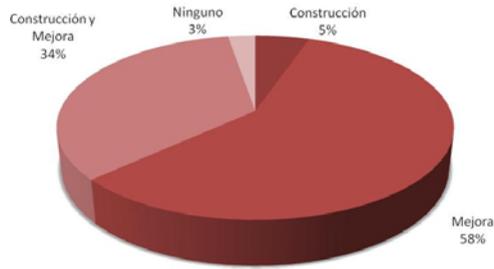


Figura 5.1.2 Distribución de artículos según clasificación de Waghodekar.

a) Generación de la solución (Construcción)

En este tipo de métodos, la distribución en planta es el resultado de una serie de decisiones tomadas bajo diferentes criterios. Realmente se trata de un método para la agregación de opiniones de varios expertos, al calificar los grados de relación entre actividades, y tomando estas opiniones en la fase de generación de la solución.

Waghodekar y Sahu incluyen en este grupo técnicas de su propia creación como MFLAP, publicada en (Waghodekar y Sahu 1986), siendo el artículo de (Meller y Gau 1996), la única referencia adicional que podamos asignar a esta categoría.

| | |
|--------------------------|---------------------|
| (Waghodekar y Sahu 1986) | (Meller y Gau 1996) |
|--------------------------|---------------------|

b) Selección de la alternativa (Mejora)

El procedimiento de selección de alternativas se lleva a cabo mediante alguna metodología de análisis multicriterio que, a su vez, puede desarrollarse de dos formas distintas:

- Utilizando en la formulación del problema una función objetivo resultante de la agregación de los criterios que se desea contemplar. La forma más habitual de hacerlo es a través de modelos aditivos (suma ponderada) y en algunas referencias con modelos multiplicativos. Podemos englobar dentro de estas técnicas, las siguientes referencias:

| | | |
|------------------------------|-------------------------------|-------------------------------|
| (Rosenblatt 1979) | (Dutta y Sahu 1982) | (Fortenberry y Cox 1985) |
| (Urban 1987) | (Urban 1989) | (Malakooti 1989) |
| (Suresh y Sahu 1993) | (Shang 1993) | (Islir 1998) |
| (Chen y Sha 1999) | (Sha y Chen 2001) | (Wang, Hu y Ku 2005) |
| (Tuzkaya, Ertay y Ruan 2005) | (Aiello, Enea y Galante 2006) | (Logendran y Kriausakul 2006) |
| (Ye y Zhou 2007) | (Sahin y Türkbey 2009) | |

- Utilizando procedimientos de **jerarquización**. En este caso se realiza la generación de multitud de soluciones a un determinado problema, y posteriormente son seleccionadas mediante un procedimiento de jerarquización: ELECTRE (*ELimination Et Choix Traduisant la REalité*), AHP (*Analytic Hierarchy Process*), DEA (*Data Envelopment Analysis*)...

| | | |
|------------------------|--------------------|-------------------|
| (Cambron y Evans 1991) | (Lin y Sharp 1999) | (Yang y Kuo 2003) |
| (Yang y Hung 2007) | | |

c) Generación y selección de alternativas. (Construcción y mejora)

En (Malakooti y D'Souza 1987) se propone un método de agregación parcial interactivo. Es un procedimiento iterativo (de construcción y mejora) en el que se van generando y evaluando alternativas secuencialmente. La evaluación la realiza uno o varios expertos bajo diferentes criterios. Las opiniones expresadas son tenidas en cuenta a la hora de generar la siguiente alternativa, guiando así el procedimiento de mejora.

Podemos incluir en este apartado también algún método basado en lógica difusa, como el expuesto por (Raoot y Rakshit 1993).

| | | |
|----------------------------|-----------------------------|-----------------------------------|
| (Malakooti y D'Souza 1987) | (Khare, Khare y Neema 1988) | (Malakooti y Tsurushima 1989) |
| (Houshyar 1991) | (Harmonosky y Tothero 1992) | (Sarin et al. 1992) |
| (Raoot y Rakshit 1993) | (Badiru y Arif 1996) | (Deb y Bhattacharyya 2003) |
| (Chen y Sha 2005) | (Sangwan y Kodali 2006) | (Khilwani, Shankar y Tiwari 2008) |

El objeto de la presente investigación queda enmarcado dentro del segundo grupo, en el que la naturaleza multicriterio es tenida en cuenta en la fase de selección, empleando técnicas de mejora mediante heurística de *Simulated Annealing*.

5.1.2 Clasificación de Malakooti

En (Malakooti 1989) encontramos una segunda clasificación de las técnicas multiobjetivo aplicadas al problema de distribución en planta en función del momento en el que se tenga en cuenta el carácter multicriterio del problema.

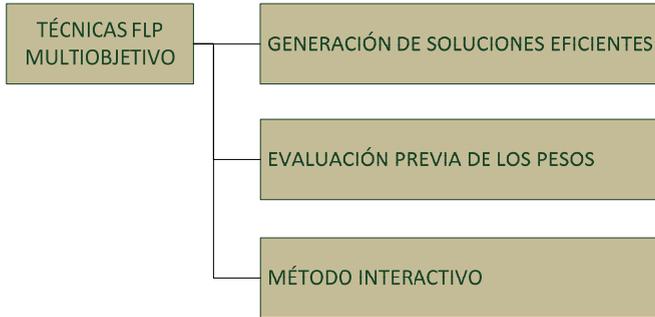


Figura 5.1.3 Clasificación de Malakooti.

Esta es la clasificación que mayor número de referencias tiene en la bibliografía, y en ella, el autor describe tres grandes grupos de técnicas: en primer lugar están las técnicas que generan una serie de soluciones que son eficientes sin centrarse en cual de todas ellas es el óptimo. En segundo lugar están las técnicas en las que se evalúa en primer lugar los pesos que hay que darle a cada uno de los objetivos, para pasar después a optimizar la función objetivo con los pesos obtenidos. Por último se describen métodos interactivos entre expertos y diseñador, que tienen en cuenta el carácter multiobjetivo del problema en el proceso de generación de la solución.

A continuación veremos que referencias podemos incluir en cada una de las categorías, aunque podemos adelantar que la gran mayoría se pueden enmarcar en la primera, tal y como se puede ver en la Figura 5.1.4:

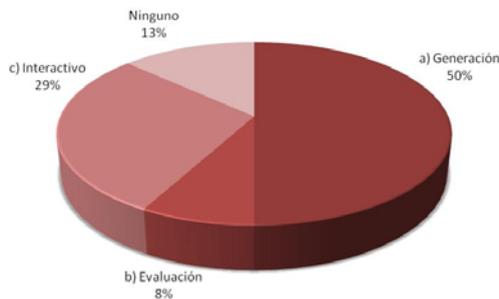


Figura 5.1.4 Distribución de artículos según clasificación de (Malakooti 1989).

a) Generación de un conjunto de soluciones eficientes

En este primer grupo de metodologías, se generan un conjunto de soluciones eficientes que posteriormente son presentadas a un panel de expertos o similar para su clasificación. La mayor parte de referencias encontradas en la bibliografía se encuentra en este primer enfoque, en el que se generan soluciones que, atendiendo a diferentes objetivos (generalmente dos, uno cuantitativo y otro cualitativo), son eficientes o no dominadas.

La generación de soluciones puede realizarse mediante la agregación de los criterios en una sola función objetivo o mediante técnicas Pareto. Dentro de este grupo podemos incluir las siguientes referencias:

| | | | |
|---------------------|-------------------------------|------------------------------|-------------------------------|
| (Rosenblatt 1979) | (Dutta y Sahu 1982) | (Fortenberry y Cox 1985) | (Waghodekar y Sahu 1986) |
| (Urban 1987) | (Urban 1989) | (Malakooti 1989) | (Harmonosky y Totho 1992) |
| (Sarin et al. 1992) | (Suresh y Sahu 1993) | (Islier 1998) | (Chen y Sha 1999) |
| (Sha y Chen 2001) | (Aiello, Enea y Galante 2006) | (Tuzkaya, Ertay y Ruan 2005) | (Logendran y Kriausakul 2006) |
| (Ye y Zhou 2007) | (Sahin y Türkbey 2009) | | |

b) Evaluación previa de los pesos de los objetivos.

En un segundo grupo, Malakooti agrupa todas aquellas técnicas en las que se comienza evaluando las preferencias del panel de expertos primero, generando los pesos para cada uno de los criterios y poder obtener así la mejor solución. (Malakooti y D'Souza 1987) desarrollaron una metodología de comparación de pares basada en la intensidad de preferencia entre soluciones, generando los pesos de los objetivos mediante una función que asume lineal. Posteriormente, otros autores han aplicado ésta misma técnica:

| | | |
|----------------------------|---------------------|-------------------|
| (Malakooti y D'Souza 1987) | (Meller y Gau 1996) | (Chen y Sha 2005) |
|----------------------------|---------------------|-------------------|

c) Método interactivo para encontrar la mejor solución.

Por último, el tercer grupo de técnicas se engloban las metodologías en las que se presenta un proceso interactivo, que requiere las respuestas del experto a ciertas cuestiones establecidas por el programador, obteniendo tanto los pesos como la obtención de la mejor solución. La primera referencia de este tipo, aunque no aplicada al problema de distribución en planta la podemos encontrar en (Malakooti y Ravindran 1985), posteriormente podemos encontrar esta misma técnica en:

| | | |
|-----------------------------------|-------------------------------|-------------------------|
| (Khare, Khare y Neema 1988) | (Malakooti y Tsurushima 1989) | (Houshyar 1991) |
| (Raoot y Rakshit 1993) | (Shang 1993) | (Badiru y Arif 1996) |
| (Deb y Bhattacharyya 2003) | (Aiello, Enea y Galante 2006) | (Sangwan y Kodali 2006) |
| (Khilwani, Shankar y Tiwari 2008) | | |

Algunas de las referencias encontradas no se pueden enmarcar en ninguno de estos grupos, bien porque se trate de aproximaciones de evaluación de soluciones, o porque la técnica no se ajuste a ninguna de las anteriormente descritas:

| | | | |
|-----------------------------------|------------------------|--------------------|-------------------|
| (Rosenblatt y Sinuany-Stern 1986) | (Cambron y Evans 1991) | (Lin y Sharp 1999) | (Yang y Kuo 2003) |
| (Yang y Hung 2007) | | | |

El objeto de la presente investigación queda enmarcado en la primera categoría, pues es una metodología de generación de soluciones eficientes, en nuestro caso un conjunto de soluciones que conforman la frontera de Pareto.

5.1.3 Clasificación propuesta

En el estudio de las diferentes referencias publicadas en el ámbito del problema de distribución en planta multiobjetivo, el autor ha decidido estructurar y organizar las mismas atendiendo a una clasificación diferente a las comentadas anteriormente.

En un primer nivel, se distribuyen las publicaciones en dos grandes grupos en función de la forma en la que se aborda el problema:

- **Evaluación de Soluciones:** En un primer grupo se incluyen las referencias que tienen como objetivo fundamental determinar la mejor de las soluciones de un conjunto de *layouts* generados mediante cualquier técnica de construcción.
- **Optimización de Soluciones:** En este segundo grupo se incluyen todas las referencias que tienen como objetivo la generación de soluciones optimizadas a partir de un *layout* original. Todas estas técnicas se pueden clasificar en función de cómo se realiza la optimización bien a través de una función objetivo en la que se agregan todos los objetivos o bien se afronta el problema como multiobjetivo a través de un conjunto de soluciones que conforman la frontera de Pareto.



Figura 5.1.5 Clasificación propuesta.

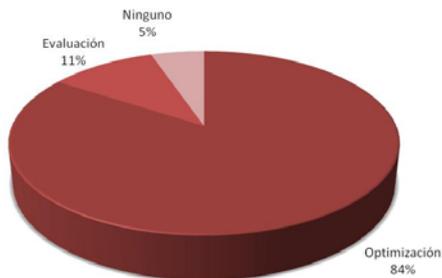


Figura 5.1.6 Distribución de artículos según clasificación propia.

5.2 EVALUACIÓN DE SOLUCIONES

Algunos autores se han acercado al problema de distribución en planta desde el punto de vista de la selección de diferentes alternativas (o evaluación de soluciones). En sus propuestas, se generan una serie de soluciones, mediante cualquier técnica de generación existente y posteriormente se evalúan, obteniendo de entre las soluciones generadas la mejor atendiendo a los diferentes objetivos.

Las referencias de la bibliografía que podemos enmarcar dentro de este grupo son las siguientes:

| | | |
|-------------------------------|------------------------|--------------------|
| (Malakooti y Tsurushima 1989) | (Cambron y Evans 1991) | (Lin y Sharp 1999) |
| (Yang y Kuo 2003) | (Ye y Zhou 2007) | |

Veamos cada una de ellas con los aspectos más interesantes y sus aportaciones principales.

Malakooti y Tsurushima

En (Malakooti y Tsurushima 1989), se propone una metodología mixta MCDM-ES, que combina los conceptos de la toma de decisiones multicriterio y de un sistema experto (ES).

En una primera fase, el sistema experto construye una serie de soluciones según los criterios establecidos por los conocimientos previos y criterios de los expertos, con lo cual se actúa en la fase de construcción de la solución, que no es generado de forma aleatoria.

En la fase de construcción intervienen los siguientes elementos:

1. *Base de datos*: En este elemento se encuentra toda la información que define el problema, número y tamaño de actividades, flujo entre actividades...
2. *Base de conocimientos*: Contiene conocimientos del FLP adquiridos de la experiencia, incluyendo heurísticas, reglas de decisión... En este caso, los autores emplean una serie de reglas IF-THEN en las que se apoyan para la construcción de la solución.
3. *Base de prioridades*: En este elemento se encuentran las reglas para determinar la prioridad entre los diferentes criterios, para priorizar soluciones. Aquí es donde mayor es la influencia de los expertos, que son los que marcan las prioridades de proximidad, de adyacencia o de posición entre actividades.
4. *Motor de decisión*: Controla y gestiona las bases a la hora de construir las nuevas soluciones.

En la segunda fase, de mejora, se permite a los expertos modificar la posición de algunas actividades para mejorar la calidad de la solución. Estos cambios solo se pueden hacer por el panel de expertos y son guiados por ellos, sin emplear ninguna heurística de mejora.

Aplican la metodología a un problema monocasilla de 4 actividades propio.

Cambron y Evans

En (Cambron y Evans 1991) se generan seis soluciones a un problema de distribución en planta de 25 actividades de área desigual mediante técnicas como CRAFT, CORELAP, ALDEP y una generación manual que posteriormente son clasificadas atendiendo a diferentes criterios.

En concreto se evalúan criterios tanto cuantitativos (eficiencia de movimiento de materiales y personal, espacios muertos...) como cualitativos (Seguridad, Control de Ruidos, Supervisión del trabajo, Estética...), mediante una técnica AHP (*Analytic Hierarchy Process*) descrita en (Saaty 1986).

Lin y Sharp

En (Lin y Sharp 1999) encontramos una aproximación novedosa al problema de evaluación de alternativas a un problema de distribución en planta. En la misma, los autores completan el trabajo que emprendieron en (Lin y Sharp 1996) y (Lin y Sharp 1996). En los artículos precedentes, se establecieron una serie de 18 objetivos, que se materializan a través de indicadores, que, jerarquizados son el marco de trabajo para evaluar las alternativas.

En este último artículo se establece una metodología novedosa para la evaluación de diferentes alternativas. Se hace un especial hincapié a la forma de generar los pesos de cada criterio, así como de la normalización de los mismos.

El resultado es una metodología muy detallada, aunque algo complicada para la evaluación de las alternativas, y que contempla multitud de objetivos e indicadores (tanto cuantitativos como cualitativos) y que se escapa al alcance del presente trabajo.

Se aplica la misma a la selección entre dos alternativas de un problema multiclasilla con pasillos, para los que obtiene el valor de comparación D_k , que es la suma ponderada y normalizada de los 18 indicadores comentados anteriormente.

Yang y Kuo

En (Yang y Kuo 2003) se hace una aproximación novedosa al problema de distribución en planta, pues los autores plantean una técnica que no está basada en la agregación de objetivos en una sola función, sino que emplean DEA (*Data Envelopment Analysis*) para realizar la selección de la mejor solución de entre las generadas.

Los autores plantean el problema atendiendo a criterios tanto cuantitativos (Flujo, Adyacencia y Factor de Forma) como cualitativos (Flexibilidad, Accesibilidad y

Mantenimiento). De entre estos criterios destaca el Factor de Forma (*Shape Ratio*), que será tratado en apartados posteriores de este trabajo.

Los criterios cualitativos se ponderan y evalúan mediante AHP, y los cualitativos se evalúan una vez construida la solución (que se hace mediante SPIRAL). La decisión sobre cual es mejor solución de entre las generadas se realiza mediante DEA, que es una aproximación no paramétrica, que no requiere ningún supuesto sobre la forma de la función objetivo.

El problema se aplica sobre un ejemplo propio de 10 actividades de diferente área, empleando geometría continua y una técnica de colocación similar a los *flexbay*, como métrica se emplea la distancia rectilínea.

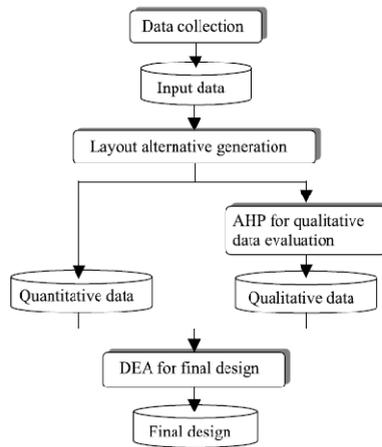


Figura 5.2.1 Esquema de la metodología (Yang y Kuo 2003).

En (Yang y Hung 2007) encontramos un nuevo planteamiento del problema de decisión con múltiples objetivos, similar al establecido en (Yang y Kuo 2003) donde se deben elegir la mejor entre distintas soluciones a un problema de distribución en planta.

En este caso los autores emplean las mismas soluciones obtenidas en artículos anteriores, atendiendo a los mismos criterios y determinan la mejor de ellas empleando una variación de la metodología TOPSIS (*Technique for Order Preference by Similarity to Ideal Solution*) establecida por (Hwang y Yoon 1981), que se fundamenta en el principio de que la alternativa elegida debe situarse a la menor distancia de la solución óptima y a la mayor distancia a la solución pésima.

La metodología, a la que llaman Fuzzy TOPSIS, introduce conceptos de la lógica borrosa en la original, obteniendo soluciones aceptables, que son comparadas con las que se recogían en el problema test de 10 actividades de (Yang y Kuo 2003).

5.3 OPTIMIZACIÓN DE SOLUCIONES

Gran parte de los autores que se han aproximado al problema de distribución en planta desde un punto de vista multiobjetivo, lo hacen desde una de las formulaciones del problema como es la del QAP (*Quadratic Assignment Problem*) y más concretamente en el QAP monocasilla o monoárea. En este problema fue planteado en (Koopmans y Beckman 1957) y en el mismo se deben asignar n actividades a n localizaciones, de manera que el coste total resultante del producto de los flujos por las distancias entre actividades sea mínimo. En el problema generalizado las áreas de las n actividades pueden tener valores distintos, sin embargo en el problema monocasilla o monoárea son iguales, de valor unidad y de geometría cuadrada.

En este tipo de formulación, cada actividad solo puede ser asignada a una única localización, no permitiendo la superposición de las mismas. En la Figura 5.3.1 se muestra un ejemplo de un problema de asignación para $n=5$ formulado como un QAP.

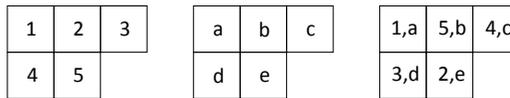


Figura 5.3.1 Actividades, Localizaciones y Asignación de actividad a localización para $n=5$.

La formulación QAP del problema de distribución en planta, exige la definición de una variable de decisión o asignación de acuerdo con la siguiente expresión:

$$x_{ik} = \begin{cases} 1 & \text{si la actividad } i \text{ está en la localización } k. \\ 0 & \text{en caso contrario.} \end{cases} \quad (5.1)$$

La nomenclatura que se emplea en la formulación del QAP generalizado (Francis y White 1974) es la siguiente:

- n Número de actividades.
- ub Número de localizaciones.
- A_i Área total de la actividad i .
- a_{ik} Coste de colocar la actividad i en la localización k .
- f_{ij} Flujo de materiales entre la actividad i y la act. j para un periodo de referencia.
- c_{ij} Coste de transporte por unidad de distancia, una unidad de producto desde la actividad i a la actividad j .
- d_{kl} Distancia de la localización k a la localización l .

Con las siguientes consideraciones:

1. a_{ik} incluye exclusivamente el coste de instalación
2. f_{ij} es independiente de la localización de las actividades.
3. c_{ij} es independiente de las actividades, depende del sistema de mantenimiento.
4. Es más barato transportar material directamente desde la actividad i a una actividad j que a través de una tercera localización.

Con todas las consideraciones y nomenclatura anteriormente expuesta, la formulación del problema de distribución en planta como un QAP generalizado queda de la siguiente forma:

$$\text{Min} \quad \sum_{i=1}^n \sum_{k=1}^{ub} a_{ik} \cdot x_{ik} + \sum_{i=1}^n \sum_{j=1}^n \sum_{k=1}^{ub} \sum_{l=1}^{ub} f_{ij} \cdot c_{ij} \cdot d_{kl} \cdot x_{ik} \cdot x_{jl} \quad (5.2)$$

Sujeto a las siguientes restricciones:

$$\sum_{k=1}^{ub} x_{ik} = A_i \quad i = 1, 2, \dots, n \quad (5.3)$$

$$\sum_{i=1}^n x_{ik} = 1 \quad k = 1, 2, \dots, ub \quad (5.4)$$

$$x_{ik} = x_{ik}^2 \quad (5.5)$$

El primer término de la expresión (5.2) computa el coste de asignar la actividad i a la localización k , es lo que se llama el *coste de instalación*. Este término se considera nulo en todas las formulaciones multiobjetivo del problema de distribución en planta encontradas en la bibliografía.

El segundo término de la expresión, computa el coste de transporte de materiales entre las actividades i y j , cuando están localizadas en las posiciones k y l , esta forma de plantear el problema en términos de coste de transporte es una formulación cuantitativa.

Las restricciones de esta formulación del problema se interpretan de la siguiente forma:

- La restricción (5.3) establece que para cada una de las n actividades, la suma de celdas que ocupa la actividad debe ser igual al área de la actividad (cada casilla es una unidad de área). Esta restricción se simplifica para el caso del QAP monocasilla, pues el valor de n_i es siempre igual a la unidad.
- La segunda restricción (5.4) vela por la no superposición de actividades en una misma celda, por ello la suma de las variables de asignación de las n actividades en cada una de las k localizaciones debe ser unitaria.

- Por último la restricción (5.5) controla el valor de la variable de asignación, es una manera simplificada de la ecuación (5.1).

En las formulaciones QAP multiobjetivo del FLP revisadas en toda la bibliografía, el coste de implantación es nulo, y en la mayor de ellas, se reducen al modelo monocasilla ($n=ub$), que puede ser reducida a la siguiente expresión:

$$\text{Min} \quad \sum_{i=1}^n \sum_{j=1}^n \sum_{k=1}^n \sum_{l=1}^n m_{ijkl} \cdot x_{ik} \cdot x_{jl} \quad (5.6)$$

Sujeto a las siguientes restricciones:

$$\sum_{k=1}^n x_{ik} = 1 \quad i = 1, 2, \dots, n \quad (5.7)$$

$$\sum_{i=1}^n x_{ik} = 1 \quad k = 1, 2, \dots, n \quad (5.8)$$

$$x_{ik} = x_{ik}^2 \quad (5.9)$$

En la que m_{ijkl} es la función objetivo del problema, en el caso monobjetivo cuantitativo de la formulación del QAP $m_{ijkl} = a_{ijkl} = f_{ij} \cdot c_{ij} \cdot d_{kl}$, y en el resto de aproximaciones multiobjetivo varía tal y como veremos en apartados posteriores. Esta misma formulación del problema es válida, para el caso monocasilla y en aquellas situaciones en las que el coste de instalación de la actividad no fuera nulo, empleando la función objetivo: $m_{ijkl} = a_{ijkl} = c_{ik} + f_{ij} \cdot c_{ij} \cdot d_{kl}$. Siendo c_{ik} el coste de implantar la actividad i en la posición k .

La distribución de las publicaciones que realizan la optimización de las soluciones es:

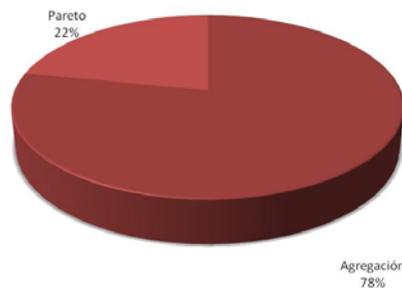


Figura 5.3.2 Distribución de publicaciones de Optimización de Soluciones.

5.3.1 Métodos basados en funciones agregadas

La mayor parte de las publicaciones de la bibliografía quedan enmarcadas en este grupo, en el que los objetivos son agregados en una única función objetivo. La agregación de objetivos se realiza bien mediante una función aditiva o mediante una función multiplicativa.

En la mayor parte de estas aproximaciones, se emplea una formulación del tipo QAP monocasilla como la mostrada en la ecuación (5.6), y la diferencia estriba en la función objetivo m_{ijkl} , tal y como veremos en el análisis de los artículos.



Figura 5.3.3 Métodos basados en funciones agregadas.

5.3.1.1 Función objetivo agregada aditiva

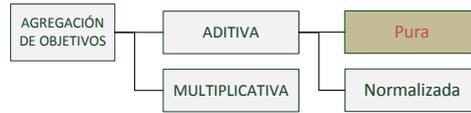
En este tipo de aproximaciones, se deben obtener en primer lugar los pesos de los m objetivos (ω_u), cumpliéndose en la mayor parte de los casos que $\sum_{u=1}^m \omega_u = 1$. Una vez obtenidos los pesos, todos ellos se agregan obteniendo un valor único de la función objetivo m_{ijkl} que debe ser minimizada, en general:

$$m_{ijkl} = \sum_{u=1}^m \omega_u \cdot f_{ijkl,u} \quad (5.10)$$

Donde: ω_u Es el peso de objetivo u -ésimo.

$f_{ijkl,u}$ Es el valor del objetivo u -ésimo.

Dentro de los métodos aditivos podemos encontrar dos formas de realizar la ponderación de los objetivo: por un lado los autores que emplean una adición que hemos denominado “pura”, en la que los pesos no son normalizados, por tanto la suma no tiene en cuenta la posible disparidad entre las magnitudes de los objetivos, y por otro lado los métodos aditivos “normalizados”, en los que sí que se realiza una homogeneización de los distintos objetivos, para que la función a optimizar sea lo más uniforme posible.



Aditiva Pura

En estas aproximaciones, la adición de los diferentes objetivos se realiza de manera ponderada sin normalizar los valores de los mismos. Las referencias que afrontan el problema de esta forma son las siguientes:

| | | | |
|-------------------------------|-------------------------|--------------------------|----------------------------|
| (Rosenblatt 1979) | (Dutta y Sahu 1982) | (Waghodekar y Sahu 1986) | (Malakooti y D'Souza 1987) |
| (Malakooti 1987) | (Houshyar 1991) | (Suresh y Sahu 1993) | (Meller y Gau 1996) |
| (Logendran y Kriausakul 2006) | (Sangwan y Kodali 2006) | | |

A continuación se realiza un resumen de las aportaciones de cada una de estas referencias al problema de distribución en planta multiobjetivo.

Rosenblatt

La primera aportación del problema de distribución en planta (FLP) como un problema multiobjetivo es publicada en (Rosenblatt 1979). El autor realiza un estudio del problema de distribución en planta con una formulación QAP multiobjetivo monocasilla, combinando dos criterios que caracteriza como *antagónicos*, como son el MHC (*Material Handling Cost*) y el CR (*Closeness Rating*) o lo que es lo mismo el coste de transporte y el índice de cercanía.

En su planteamiento, Rosenblatt establece dos funciones objetivo, a las que llama Z_x (F.O. de coste de transporte, por tanto a minimizar) y Z_y (F.O. de índice de cercanía, por tanto a maximizar), combinándolas ambas en un único problema a resolver:

$$Min Z = \alpha_2 \cdot z_x - \alpha_1 \cdot z_y = \sum_{i=1}^n \sum_{j=1}^n \sum_{k=1}^n \sum_{l=1}^n (\alpha_2 \cdot a_{ijkl} - \alpha_1 \cdot w_{ijkl}) \cdot x_{ik} \cdot x_{jl} \tag{5.11}$$

$$\alpha_2 + \alpha_1 = 1 \quad y \quad \alpha_2, \alpha_1 \geq 0 \tag{5.12}$$

Sujeto a las restricciones habituales del QAP (5.7), (5.8), (5.9) y adicionalmente a (5.12), relativa a los pesos de los criterios cuantitativos (α_2) y cualitativos (α_1) que tienen una relación lineal. Por tanto la función que relaciona ambos criterios es aditiva ponderada, y se formula: $m_{ijkl} = \alpha_2 \cdot a_{ijkl} - \alpha_1 \cdot w_{ijkl}$

En esta formulación se introduce el término del índice de cercanía de las actividades i - j , mediante el término w_{ijkl} , que adquiere el siguiente valor:

$$w_{ijkl} = \begin{cases} r_{ij} & \text{si las posiciones } k \text{ y } l \text{ tienen frontera común} \\ 0 & \text{en cualquier otra situación} \end{cases} \tag{5.13}$$

r_{ij} índice de cercanía deseado para las actividades i y j

Define, por primera vez el concepto de **layout eficiente**: “...Un layout es eficiente si una mejora, medida en uno de los criterios, solo se puede obtener aceptando una pérdida en el otro criterio...” establece también el concepto de **solución dominada** (aunque no la llame de esta manera). Describe este concepto mediante un par de soluciones i y j tales que:

$$\text{Si } R_j \leq R_i \wedge C_j \geq C_i / \forall \alpha_1, \alpha_2 \geq 0 : \alpha_2 \cdot C_i - \alpha_1 \cdot R_i \leq \alpha_2 \cdot C_j - \alpha_1 \cdot R_j \quad (5.14)$$

Se generan un conjunto de soluciones aleatorias mediante ALDEP, construyendo lo que el autor llama el *conjunto frontera eficiente* $\{E\}$ (*layout efficient set*), para conformarlo se compara la nueva solución generada con todos los que ya están en la frontera y se va actualizando el conjunto hasta que se han generado N soluciones.

Una vez generado el conjunto $\{E\}$, realiza un estudio para ver en que rangos de los pesos α , es cada una de las soluciones del conjunto eficiente $\{E\}$ la mejor. Lo aplica a un problema test de 6 actividades al que asigna flujos y una TRA que convierte en valores según el criterio empleado en (Moore 1971).

Dutta y Sahu

(Dutta y Sahu 1982) emplean una formulación idéntica a la descrita por Rosenblatt, con una diferencia en el planteamiento, pues no hablan de conjunto eficiente, sino que tienen en cuenta una función objetivo aditiva ponderada, en la que se determina directamente el valor del coste “relacional” y del coste de transporte de materiales. Esta función, aunque con diferente nomenclatura es idéntica a la de Rosenblatt: $m_{ijkl} = \alpha_2 \cdot a_{ijkl} - \alpha_1 \cdot w_{ijkl}$.

Proponen un algoritmo de optimización, mediante el empleo de un método de mejora, en el que partiendo de una configuración inicial generada aleatoriamente se van realizando intercambios de actividades y evaluando la función objetivo, aceptando el primer cambio que mejore la función objetivo. Es por tanto un algoritmo “*steepest descent*” que tiene problemas de anclaje en óptimos locales.

Realiza experimentos con 2 problemas test monocasilla: el de Rosenblatt de 6 actividades con 4 rearranques aleatorios y uno nuevo de 8 actividades con 3 rearranques. Proporcionan los datos obtenidos y al igual que Rosenblatt realiza un estudio de los resultados obtenidos en función de los valores que se asignen a los pesos de los dos criterios.

Los resultados obtenidos no son comparables con los de Rosenblatt, porque Dutta y Sahu consideran que dos actividades no son adyacentes a menos que compartan un lado en su configuración, mientras que Rosenblatt considera que con compartir la esquina es suficiente, tal y como se muestra en la Figura 5.3.4. Éste y otras cuestiones fueron fuente de intercambio de comentarios entre los autores en (Rosenblatt 1983) y (Dutta y Sahu 1983).

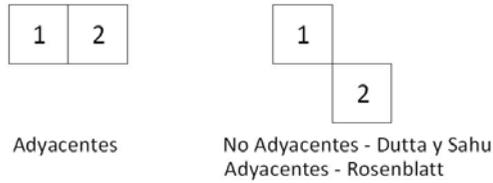


Figura 5.3.4 Consideraciones de frontera para Rosenblatt y Dutta.

Waghodekar y Sahu

En el artículo de (Waghodekar y Sahu 1986), se establece una nueva metodología (MFLAP) para resolver el problema multiobjetivo, en la que se tiene en cuenta el cariz multiobjetivo del problema durante la fase de construcción.

La formulación se realiza para el caso de tener M objetivos, aunque finalmente solo lo aplica a dos clásicos, el coste de transporte (al que llama TFC, *Total Flow Cost*) y al coste relacional entre actividades (al que llama TCR, *Total Closeness Rating*).

En la fase previa a la construcción de la solución, los autores proponer realizar una serie de matrices de las que se pueden obtener relaciones de proximidad entre las actividades, y así formular un algoritmo para la colocación de las mismas.

Los coeficientes propuestos son los siguientes:

- SCW_{jk} : Coeficiente de similitud ponderado entre las actividades j y k para todos los objetivos.
- SCA_{jk} : Suma de los coeficientes de similitud entre las actividades j y k obtenidos de forma independiente para cada objetivo.
- SCC_{jk} : Coeficiente de similitud ponderado para las celdas j y k, para todos los objetivos.

Todos los coeficientes anteriores se calculan para todos los pares de actividades j-k y se obtienen las matrices SCW, SCA y SCC, así como los valores de los coeficientes de cada actividad j ($SCWT_j$, $SCAT_j$ y $SCCT_j$).

Una vez conocida la secuencia de entrada de actividades y la forma en la que se va a realizar el relleno, comienza el proceso de optimización, en el que se emplea la formulación aditiva ponderada que habían empleado ya Dutta y Rosenblatt.

Utilizan como problemas de test los de 6 y 8 actividades de Dutta y el de 5 actividades de (Sayin 1981).

Malakooti y D'Souza

En (Malakooti y D'Souza 1987) encontramos una aproximación al problema en el que la formulación del problema vuelve a ser mediante una función objetivo agregada, aunque es sutilmente diferente a lo previamente publicado, fundamentalmente en la forma en la que aborda el problema, pues establece una metodología para obtener los pesos de los criterios ω_u mediante un panel de expertos. Podemos considerarla una técnica de construcción y mejora, pues aborda el problema en ambas fases del proceso.

Proponen también el empleo de una heurística de optimización de intercambio de actividades adaptado para el problema multiobjetivo, en el que tienen en cuenta también la posible modificación de los pesos de cada criterio. La metodología la llaman CAFLAS y la aplican al problema QAP monocasilla modificado, con una serie de valores preestablecidos para los objetivos estudiados, que en este caso son:

1. Coste Mínimo: Un objetivo ya empleado en aproximaciones anteriores, pues es el equivalente al MHC o coste de transporte de materiales.
2. Flexibilidad: Los autores definen este objetivo como: *"...la facilidad por la cual las actividades pueden ser colocadas u recolocadas, por tanto puede ser medida en términos de índice de cercanía..."* por tanto es un objetivo medido en términos cualitativos, empleando una escala de A-U en función de los beneficios en términos de flexibilidad que un experto determine para cualquiera dos actividades.
3. Tiempo de movimiento de materiales: Tiene en cuenta el tiempo que tardan los materiales en moverse por la solución, para lo cual debemos conocer el tipo de sistema de manutención empleado en cada caso. La forma en la que computa este tiempo es similar a la del MHC, multiplicando tiempos por distancias.

Malakooti

En (Malakooti 1987) continua en la misma línea que el artículo anterior, y describe en detalle la metodología CAFLAS, aplicándola a un ejemplo de áreas desiguales de 10 actividades, el modelo geométrico que emplea es discreto. Los objetivos son los mismos que los empleados en la anterior publicación TMHC, Flexibilidad y el tiempo de movimiento de los materiales.

La metodología CAFLAS tiene dos etapas, una primera en la que se determina el vector de pesos, al que llama gradiente y una segunda etapa en la que se generan una serie de soluciones basadas en el intercambio de actividades, son aceptadas siempre que sean eficientes y por último el sistema de expertos (DM) decide qué solución es la mejor.

En la segunda etapa, el valor decisivo para aceptar la solución como válida se obtiene mediante una función objetivo agregada aditiva pura, en la que los pesos no normalizan el valor de los objetivos.

Houshyar

En (Houshyar 1991) se propone un nuevo método aditivo ponderado, y se centra fundamentalmente en la obtención de los valores de los pesos de cada uno de los objetivos. La formulación es similar a la empleada en los artículos precedentes de Rosenblatt, Dutta y Fortenberry, con una diferencia fundamental y es que el autor emplea objetivos Cualitativos (R_{ijkl}) y Cuantitativos (C_{ijkl}), agrupándolos de manera aditiva en el caso de que existan más de uno de cada tipo (fundamentalmente en el caso de criterios cualitativos). La función objetivo ponderada que emplea el autor es:

$$m_{ijkl} = \omega_R \cdot R_{ijkl} - (1 - \omega_R) \cdot C_{ijkl} \quad (5.15)$$

Propone un algoritmo para determinar el peso preferente del experto (ω_R), con ese peso se generan una serie de soluciones que se presentan al experto para seleccionar el óptimo. En primer lugar evalúa los problemas monobjetivo, obteniendo los valores máximos y mínimos de los mismos, para tener valores de extremos positivos y negativos. Genera una serie de soluciones mediante CRAFT y CORELAP, obteniendo de ellas los valores de cada uno de los objetivos. Posteriormente se depuran las soluciones y se crea una lista con las soluciones eficientes, presentándola posteriormente al experto, para que determine cuál de ellas es la mejor, de la cual se extrae el valor del peso (ω_R). Aplica el algoritmo a los ejemplos de 6, 8 y 12 actividades de Rosenblatt, Dutta y Fortenberry.

Suresh y Sahu

En (Suresh y Sahu 1993) se acuña el acrónimo MOFL (*Multi Objective Facility Layout*), para agrupar a los problemas multiobjetivo de distribución en planta.

En su artículo, que en cierta medida es continuación del anterior, los autores plantean una metodología en la que agregan criterios cuantitativos (Coste) y cualitativos (índice de cercanía), para estos últimos se emplea una tabla de transformación que ya se comentó en la que se asigna a cada relación un valor numérico (A=6, ..., U=2, X=1).

La función objetivo es agregada ponderada, con un peso al que llaman α , aunque no fijan el método para determinar su valor:

$$\text{Min } E = (1 - \alpha) \cdot C - \alpha \cdot R \quad (5.16)$$

En realidad, esta formulación es exactamente la misma que planteó Rosenblatt.

Como técnica de optimización emplea un *Simulated Annealing* y lo aplica a una serie de problemas QAP de 6 y 8 actividades monocasilla, comparando los resultados con los que obtuvieron en (Dutta y Sahu 1982). Además, lo aplican a problemas QAP monocasilla, tomados de (Nugent, Vollman y Ruml 1968) de 12, 15, 20 y 30 actividades, comparando los resultados con los que obtuvieron autores anteriores.

Meller y Gau

En (Meller y Gau 1996), se hace una aproximación al problema, mediante una función objetivo aditiva, con una formulación diferente a la propuesta por (Rosenblatt 1979). La diferencia fundamental estriba en que separa los términos cuantitativo y cualitativo, pues éste último se formula en términos de adyacencia.

Los autores tienen un especial interés en dar una interpretación física a los pesos de los diferentes criterios, así como de determinar los valores críticos de los mismos, formulada:

$$\min \left(\sum_{i=1}^n \sum_{j=1}^n a_{ij} \cdot f_{ij} + \sum_{i=1}^n \sum_{j=1}^n \sum_{k=1}^{ub} \sum_{l=1}^{ub} f_{ij} \cdot c_{ij} \cdot d_{kl} - \sum_{i=1}^n \sum_{j=1}^n w_{ij} \cdot r_{ij} \cdot x_{ij} \right) \quad (5.17)$$

Donde el primer término de la expresión es el coste de trasladar una unidad de carga desde la actividad i a la actividad j . Es por tanto un coste fijo, independiente de la ubicación de las actividades, por tanto no se tiene en cuenta en la minimización de la función objetivo. Las restricciones son las mismas que se expresaron en (5.7), (5.8) y (5.9).

El segundo término tiene en cuenta el coste cuantitativo relativo al flujo de materiales entre actividades (MHC), y que en el caso del QAP monocasilla se generaliza con $n=u$, es decir el mismo número de actividades (n) que localizaciones (ub).

El tercer término considera el coste relativo a la adyacencia de las actividades. En el mismo:

- w_{ij} es el peso que pondera los criterios, con unidades de metros/viaje y se puede interpretar como "cuantos metros por viaje ahorramos por tener las actividades i - j adyacentes".
- r_{ij} es el valor numérico del índice de cercanía entre actividades.
- x_{ij} es el indicador de adyacencia, vale 1 si las actividades i y j son adyacentes y 0 en caso contrario.

Esta expresión se reduce a la siguiente para los problemas test que se evalúan:

$$\min \left(\sum_{i=1}^n \sum_{j=1}^n \sum_{k=1}^{ub} \sum_{l=1}^{ub} f_{ij} \cdot c_{ij} \cdot d_{kl} + \sum_{i=1}^n \sum_{j=1}^n w_{ij} \cdot r_{ij} \cdot (1 - x_{ij}) \right) \quad (5.18)$$

Los autores acuñan el término de *layout* más robusto: "...es aquel que minimice el máximo porcentaje sobre la mejor solución de cada uno de los dos objetivos", pone como ejemplo que una solución que disminuya un 3% y un 4% en cada uno de los objetivos que otra solución que disminuya un 5% y 1%. La metodología que proponen se fundamenta en este concepto, y la llaman "*robust layout method*". En la misma comparan las soluciones obtenidas con los dos objetivos, evaluando la disminución porcentual en cada uno de ellos. En la referencia, también se demuestra que el planteamiento es el mismo que el realizado por Rosenblatt, siendo la función objetivo aditiva ponderada.

Logendran y Kriausakul

En (Logendran y Kriausakul 2006) encontramos una nueva aproximación al problema mediante una función objetivo aditiva ponderada, en la que se optimiza la distribución en planta desde el punto de vista del flujo de materiales (MHC) y de la forma de las actividades (*aspect ratio*). Ambos objetivos se combinan ponderados (80% MHC y 20% Forma) en una función objetivo que los autores minimizan.

La formulación empleada es no lineal y es parecida a la empleada por (van Camp, Carter y Vanelli 1991) pero multiobjetivo, incluyendo el criterio de forma, que justifica por la necesidad de que las actividades no tengan una forma irregular.

La forma de las actividades siempre será rectangular y se fijan como restricciones al problema unos valores límite inferior y superior para el Aspect Ratio de cada actividad k , que se formula como:

$$A.R._k = \frac{h_k}{w_k} \quad (5.19)$$

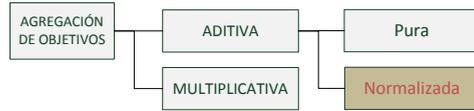
La optimización se realiza mediante *Tabú Search* y se resuelven problemas test de diferentes autores y números de actividades (5 act (Tam y Li 1991), 10 act (van Camp, Carter y Vanelli 1991), 8 act (Bazaraa 1975), 30 act (Tam y Li 1992)).

Sangwan y Kodali

Un artículo más reciente de (Sangwan y Kodali 2006) plantea el problema con una función aditiva ponderada, del mismo estilo que la propuesta en (Dutta y Sahu 1982), con los mismos objetivos, el coste de transporte de materiales (MHC) y un índice de cercanía.

En este caso los pesos de cada uno de los objetivos se obtienen mediante una combinación de lógica borrosa y AHP y la diferencia fundamental con otros procedimientos es que los valores de los índices de cercanía entre actividades se obtienen mediante lógica borrosa, y configuran lo que los autores denominan la *Fuzzy Closeness Rating Matrix*. La heurística propuesta combina estas dos técnicas para obtener la mejor solución posible.

Los autores prueban la metodología con los ejemplos de (Dutta y Sahu 1982) de 6 y 8 actividades, todos ellos con la formulación del QAP con áreas de las actividades iguales.



Aditiva Normalizada

En estas aproximaciones, la adición de los diferentes objetivos se realiza de manera ponderada normalizando los objetivos, bien a través de los pesos o bien aplicando un paso de normalización de los datos de partida del problema.

Las referencias que tienen esta forma de agregar los objetivos son las siguientes:

| | | | |
|-------------------------------------|------------------------------|--|--|
| (Urban 1989) (Sarin et al. 1992) | (Urban 1987) (Shang 1993) | (Khare, Khare y Neema 1988) (Chen y Sha 1999) | (Harmonosky y Tothero 1992) (Sha y Chen 2001) |
| (Deb y Bhattacharyya 2003) | (Chen y Sha 2005) | (Khilwani, Shankar y Tiwari 2008) | (Singh y Singh 2009) |

Se podría hacer una diferencia clara entre las referencias que emplean una carga estadística importante a la hora de realizar la normalización de los objetivos y las que no lo hacen. A continuación se profundizará en estos detalles en el estudio de cada referencia.

Urban

El artículo de (Urban 1987) es el primero que intenta resolver el problema de la falta de normalización entre los criterios empleados en la formulación multiobjetivo del problema e introduce una formulación aditiva con la función objetivo:

$$m_{ijkl} = f_{ij} + c \cdot r_{ij} \quad (5.20)$$

Donde c es una constante (peso) para determinar la importancia relativa del índice de cercanía con el flujo ($c \geq 0$). Por tanto $c = c(f_{ij})$, para hacer que el mismo sea insensible al sistema de manutención empleado y a los volúmenes de flujo del problema. Con esta formulación aditiva evita los problemas que surgen con el modelo multiplicativo de Fortenberry, pues se consigue:

- Separar suficientemente las actividades con índices de cercanía malos, particularmente las que tienen un flujo de material bajo.
- Permitir que el índice de cercanía influya en el coste de la solución para todos los pares de actividades independientemente de la distancia que haya entre ellos.

Al valor $m_{ijkl} = f_{ij} + c \cdot r_{ij}$, el autor le llama Factor de Carga y para cada par de actividades, se determina un valor numérico, asignando al término cualitativo valores numéricos (similares a los de Fortenberry, $A=4, B=3, \dots, X=-1$).

Aplica el modelo a problemas de 6 y 12 actividades propuestos por Rosenblatt y Fortenberry respectivamente y con casos en los que el flujo interdepartamental es igual a

0, para demostrar la bondad de su formulación. No propone ninguna heurística nueva, sino que emplea el intercambio de pares de actividades para realizar la optimización.

En todos los casos, la constante c adquiere el valor del mayor de los flujos entre actividades.

En una publicación posterior (Urban 1989), el autor hace hincapié en este modelo y propone que la constante c , puede adquirir también el valor del promedio de los valores de flujo entre actividades y realiza gráficas *Factor de Carga – Flujo Interdepartamental*.

Khare, Khare y Neema

En (Khare, Khare y Neema 1988) encontramos una nueva aproximación al problema, en la que se vuelve a emplear una función agregada aditiva. En primer lugar hace hincapié en las diferentes aproximaciones en función del cariz de los objetivos, diferenciando:



Figura 5.3.5 Cariz de los objetivos en (Khare, Khare y Neema 1988).

Los autores tienen en cuenta dos objetivos: el MHC y el índice de cercanía, tenido en cuenta como una penalización, por tanto ambos objetivos son congruentes, y los llama TFC (*Total Flow Cost*) y TNR (*Total Numerical Rating*). Combinan ambos criterios en una función aditiva ponderada similar a la empleada por los autores anteriores:

$$MGM = W_2 \cdot TFC + W_1 \cdot TNR \tag{5.21}$$

Una de las principales aportaciones de los autores es que se plantean la optimalidad de la solución, algo que cuando el problema es de una entidad considerable es complicado de evaluar, pues computacionalmente no se pueden evaluar todas las soluciones para conocer el óptimo absoluto. Formula la expresión de la varianza de la función objetivo de coste de transporte y de índice de cercanía ponderada (5.22), y la evalúa para diferentes valores de los pesos W_2 y W_1 .

$$V_M = \frac{2}{n \cdot (n-1)} \sum_{i=1}^{n-1} \sum_{j=i+1}^n M_{ij}^2 \sum_{i=1}^{n-1} \sum_{j=i+1}^n d_{ij}^2 + \frac{16 \cdot Q_n \cdot M \cdot Q_n \cdot d}{n \cdot (n-1) \cdot (n \cdot (n-5) + 6)} - \frac{16 \cdot P_n \cdot M \cdot P_n \cdot d}{n \cdot (n-1) \cdot (n-2)} - \frac{n^2 \cdot (n-1)^2}{4} \cdot A_M^2 \cdot A_d^2 \tag{5.22}$$

Proponen un algoritmo de mejora basado en el intercambio de actividades similar al empleado por Rosenblatt o Urban, y que tiene el mismo problema con los mínimos locales. Realizan test con problemas de 6 y 12 actividades monocasilla.

Harmonosky y Tothero

En (Harmonosky y Tothero 1992) plantean un modelo discreto con una formulación clásica del QAP monocasilla como la comentada en (5.6) con las restricciones (5.7), (5.8) y (5.9) en la que los autores proponen un modelo aditivo, empleando los objetivos clásicos del MHC y el CR entre actividades, aunque teniendo éste último un carácter de penalización, con lo cual la función agregada deberá ser minimizada (los objetivos son, según lo planteado por (Khare, Khare y Neema 1988), congruentes)

La normalización de los objetivos es algo necesario, pues mientras el flujo se mide en cientos o miles de unidades, el índice de cercanía normalmente se mide en una escala de -1 a 4. Algunos autores, como Urban ya habían tenido una aproximación a la normalización, pues la constante por la que multiplicaban el índice de cercanía estaba relacionada con el máximo flujo, pero estos autores son los primeros en formular la normalización de los h objetivos, tal y como se expresa en (5.23), donde t_{iju} es el valor normalizado del objetivo u entre las actividades i y j , ya sea flujo interdepartamental, índice de cercanía ...

$$t_{iju} = \frac{T_{ij u}}{\sum_{i=1}^n \sum_{j=1}^n T_{ij u}} \quad (5.23)$$

Por tanto el primer paso es obtener las nuevas matrices normalizadas t_{ij} para cada uno de los m objetivos que se planteen en el problema. La función objetivo m_{ijkl} a emplear será:

$$m_{ijkl} = \left(\sum_{u=1}^m \alpha_u \cdot t_{iju} \right) \cdot d_{kl} \quad (5.24)$$

Adicionalmente, esta formulación añade una nueva restricción que queda implícita en (5.23), que es la siguiente:

$$\sum_{i=1}^n \sum_{j=1}^n t_{iju} = 1 \quad \forall u \quad (5.25)$$

En cuanto a la técnica de optimización, los autores proponen una técnica de construcción y mejora, en la que aplican un algoritmo de intercambio de actividades similar al empleado por autores precedentes. Aplicándolo a los problemas clásicos monocasilla de 6,8 y 12 actividades, comparando los resultados obtenidos con los históricos hasta ese momento.

Sarin

En (Sarin et al. 1992) se hace una aproximación similar a la propuesta por (Harmonosky y Totho 1992) en lo referente a la normalización de los objetivos, aunque con diferencias significativas en la forma de hacerlo. Los autores establecen, como función objetivo, el TRP (Ratio de Preferencia Total) que debe ser maximizado, y que adquiere la siguiente expresión:

$$\text{Max TRP} = \sum_{i=1}^n \sum_{j=1}^n \frac{p_{ij}}{d_{ij}} \quad (5.26)$$

En esta expresión definen el *valor de preferencia* entre un par de actividades i,j (p_{ij}), que no es más que un valor agregado de los m objetivos, y en el que estriba la diferencia con técnicas anteriores. En este caso cuanto mayor sea el valor de preferencia entre dos actividades, más cercanas deberán estar. Este valor se determina con la siguiente expresión:

$$p_{ij} = \sum_{u=1}^m C_u \cdot v_u(x_{ij u}) \quad (5.27)$$

En la que u es cada uno de los m objetivos y:

- C_u es el peso del objetivo u -ésimo.
- $v_u(x_{ij u})$ es la función de valor marginal que proporciona el índice de preferencia del objetivo u -ésimo.

Estas funciones de valor marginal no son numéricas, sino que son funciones de transformación como las mostradas en la Figura 5.3.6. Los valores de ratio de preferencia de cada uno de los objetivos están normalizados entre 0-1. En el eje de las abscisas se colocan el valor menor y mayor que puede adoptar el objetivo y en las ordenadas el índice de preferencia. La distribución interna de la función varía para cada problema y objetivo.

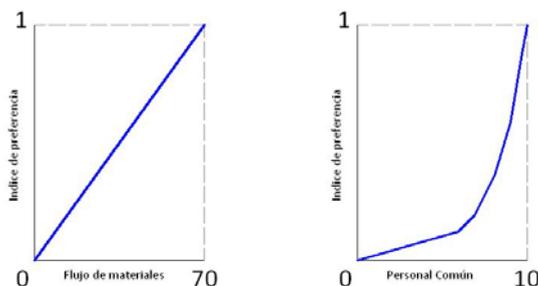


Figura 5.3.6 Funciones de valor marginal para el ejemplo de (Sarin et al. 1992).

Shang

En (Shang 1993), el autor introduce dos novedades respecto a las publicaciones anteriores:

- Determinación de los pesos de los criterios cualitativos mediante AHP.
- La normalización y ponderación de criterios se realiza de una forma diferente.

Shang emplea una formulación de QAP monocasilla similar a la formulada en (5.6) sujeto a las mismas restricciones, en la que la función objetivo (m_{ijkl}) es multicriterio, con la siguiente expresión:

$$m_{ijkl} = a_{ijkl} = d_{kl} \cdot (a \cdot f_{ij} + b \cdot c \cdot r_{ij}) \quad (5.28)$$

Es una función objetivo aditiva, en la que los criterios cuantitativos (flujo de trabajo entre actividades, f_{ij}) y los criterios cualitativos (índice de cercanía, r_{ij}) se suman, ponderados por unos pesos (a, b) y normalizados por un coeficiente (c), que el autor propone sea igual a:

$$c = \frac{\max f_{ij}}{\overline{ir_{ij}}} \quad (5.29)$$

Donde: $\overline{ir_{ij}}$: Valor medio de las intensidades relacionales existentes entre las actividades, resultante de la agregación de los criterios de naturaleza cualitativa. Para eliminar la posibilidad de indeterminación por la obtención de un valor promedio nulo se eliminan las que sean menores que la unidad.

f_{ij} : Coste, por unidad de distancia, derivado del flujo de materiales entre las actividades i y j .

La metodología se realiza en dos etapas, una primera en la que se determinan los pesos de cada uno de los criterios (cuantitativos y cualitativos), mediante AHP y una segunda en la que se realiza la optimización del problema. Otra característica a destacar es que el autor insiste en que es necesario partir de una solución inicial que tenga una calidad elevada, para poder llegar a óptimos locales.

a) *Determinación de los pesos de cada uno de los criterios (a,b_u), mediante AHP.*

En el ejemplo propuesto por Shang (4 actividades monocasilla), se realiza el cálculo de los coeficientes (a,b_u) en varios pasos:

1. Se determinan los criterios cualitativos bajo los cuales se quiere optimizar el problema (nivel 1), en el ejemplo:
 - La seguridad
 - Las molestias ocasionadas por niveles sonoros excesivos
 - La flexibilidad
 - La estética
 - La temperatura
 - El trabajo en curso.

A estos criterios, se le suma el MHC, a la hora de determinar los pesos relativos de cada uno de ellos.

2. Se expresa, a través de una escala de valores, la preferencia de proximidad entre pares de actividades bajo los diferentes criterios.

Los valores se organizan en forma de matrices Pr (pr_{sd,u}), donde pr_{sd,u} representa la preferencia de proximidad del par de actividades "s" frente al par de actividades "d" bajo el criterio u-ésimo. En la Tabla 5.3.1, se muestra un extracto de una de las matrices propuestas por Shang para el caso de 4 actividades (1,2,3,4) en uno de los criterios.

| seguridad | (1,2) | (1,3) | (1,4) | (2,3) | (2,4) | (3,4) |
|-----------|-------|-------|-------|-------|-------|-------|
| (1,2) | 1 | 1/3 | 2 | 1 | 1/4 | 3 |
| (1,3) | 3 | 1 | 5 | 4 | 2 | 1/3 |
| (1,4) | 1/2 | 1/5 | 1 | 1/3 | 1 | 1/5 |
| (2,3) | 1 | 1/4 | 3 | 1 | 2 | 1/2 |
| (2,4) | 4 | 1/2 | 1 | 1/2 | 1 | 6 |
| (3,4) | 1/3 | 3 | 5 | 2 | 1/6 | 1 |

Tabla 5.3.1 Matriz de preferencia de proximidad (Pr), bajo el criterio seguridad

3. Se calcula n_{s,u}, que es la necesidad relativa de proximidad de cada par (s) de actividades bajo los diferentes criterios (u):

$$n_s = \frac{\sum_{d=1}^t pr_{sd,u}}{\sum_{s=1}^t \sum_{d=1}^t pr_{sd,u}} \tag{5.30}$$

Siendo: t : El número de pares de actividades que se comparan $(n \cdot (n - 1) / 2)$

$pr_{sd,u}$: Preferencia de proximidad del par de actividades "s" sobre el par "d" bajo el criterio u -ésimo.

4. Se calcula la "necesidad global de proximidad" entre un par de actividades (s), resultante de la agregación ponderada de las necesidades relativas de proximidad bajo cada criterio:

$$R_s = \sum_{u=1}^m \alpha_u \cdot n_{sd,u} \quad (5.31)$$

Donde: α_u es la importancia del criterio u -ésimo, calculada por AHP.

El resultado final de esta primera parte de la metodología proporciona una matriz de índice de cercanía entre actividades, atendiendo a criterios cualitativos, para emplear en un estadio posterior de la misma.

| | A | B | C | D |
|---|-------|-------|-------|-------|
| A | X | 0.143 | 0.226 | 0.108 |
| B | 0.143 | X | 0.150 | 0.208 |
| C | 0.226 | 0.150 | X | 0.165 |
| D | 0.108 | 0.208 | 0.165 | X |

Tabla 5.3.2 Ejemplo de matriz de índice de cercanía (R_{ij}) entre actividades ($n=4$).

b) Resolución del problema

El autor, propone una heurística *Simulated Annealing* para la resolución del FLP multiobjetivo, mediante la función agregada comentada anteriormente. La metodología se compara con la de (Malakooti y D'Souza 1987), para 5, 10, 15, 20, 25 y 30 actividades obteniendo buenos resultados, aunque difíciles de comparar, pues los criterios empleados y la función objetivo son distintos.

Chen y Sha

En (Chen y Sha 1999) y (Sha y Chen 2001), los autores plantean una formulación muy similar a la introducida por (Khare, Khare y Neema 1988), en la que se emplea una aproximación al problema de distribución en planta mediante una función objetivo aditiva ponderada, en la que la normalización de los objetivos se realiza con parámetros estadísticos. El problema se formula como un QAP sujeto a las restricciones clásicas del problema (ver 4.6 a 4.9), en el que m_{ijkl} es la función objetivo:

$$m_{ijkl} = \sum_{u=1}^m \alpha_u \cdot U_u \tag{5.32}$$

Donde: α_u Son los pesos del objetivo u -ésimo.
 U_u Es el valor normalizado del objetivo u -ésimo.

Para el cálculo del valor normalizado de cada uno de los objetivos, se basan en que si la función de coste de la solución se aproxima a una distribución normal, la función de coste de cada uno de los m objetivos también se puede aproximar. Por tanto, podemos determinar las cotas superiores e inferiores, correspondientes a un nivel de confianza α , para cada objetivo u , como:

$$\begin{aligned} LCL_u &= M_u - r \cdot \sigma_u \\ UCL_u &= M_u + r \cdot \sigma_u \end{aligned} \tag{5.33}$$

Donde: M_u Es el valor medio de la distribución de coste de la solución.
 σ_u Es la desviación típica de la distribución de coste.
 R Es el nivel de confianza fijado por el diseñador.

Si el valor del objetivo u -ésimo es P_u , su valor normalizado será:

$$U_u = \frac{P_u - LCL_u}{UCL_u - LCL_u} = \frac{P_u - LCL_u}{2 \cdot r \cdot \sigma_u} \tag{5.34}$$

Los autores introducen un indicador global de la solución, al que llaman POS (Probabilidad de Superioridad), que mide la probabilidad de una solución (cuyo coste global sea LS) de ser mejor que las demás, y que se obtiene de la siguiente expresión:

$$POS = 1 - p\left(Z \leq \frac{LS - 0.5}{\sqrt{1/12 \cdot \sum_{u=1}^m \alpha_u}}\right) \tag{5.35}$$

Se construye la solución inicial mediante CORELAP y aplican una mejora mediante intercambio de actividades, quedándose con aquel intercambio que genere un mayor decremento del coste. Aplican la metodología a un ejemplo propio de 10 actividades, y comparan los resultados aplicando la normalización de (Harmonosky y Totho 1992), obteniendo mejores resultados con su metodología.

Deb y Bhattacharyya

(Deb y Bhattacharyya 2003) inciden en la línea de (Raoot y Rakshit 1993) de abordar el problema de distribución en planta mediante lógica borrosa. En el mismo emplean una función objetivo aditiva ponderada, con una normalización de los objetivos igual a la empleada en (Harmonosky y Totho 1992).

Se emplean únicamente objetivos cuantitativos, como son el PFC (coste de flujo de personal) y el DS (espacio vacío), que es un objetivo interesante, pues el modelo geométrico empleado es continuo (*Absmodel*), por tanto el espacio vacío es un valor a minimizar.

Resuelven problemas test de 5, 6 y 12 actividades y comparan sus resultados con los obtenidos por (Dweiri y Meier 1996) y (Welgama y Gibson 1993), cuyas aproximaciones al problema también fueron desde la lógica borrosa.

Chen y Sha

En (Chen y Sha 2005) se hace una aproximación al problema desde el punto de vista de intentar obtener en primer lugar la matriz de pesos de la función de agregación aditiva normalizada para el problema de distribución en planta.

Para ello propone una heurística de 5 pasos en la que determina los valores apropiados para cada uno de los pesos asociados a los objetivos, la metodología debe cumplir con los siguientes pasos:

1. Con unos valores arbitrarios de los pesos y una solución generada aleatoriamente se obtiene a través de lo expuesto en (Chen y Sha 1999), se obtiene una solución sub-óptima, denominada "BASIS".
2. Mediante un procedimiento múltiple de doblado y reducción, se obtiene la matriz de comparación por pares [A].
3. Se comprueba si la matriz [A] es consistente.
4. Si la matriz no es consistente, se genera una \bar{A} que sí que lo sea.
5. A partir de la matriz de comparación por pares consistente, se obtiene el vector de pesos.

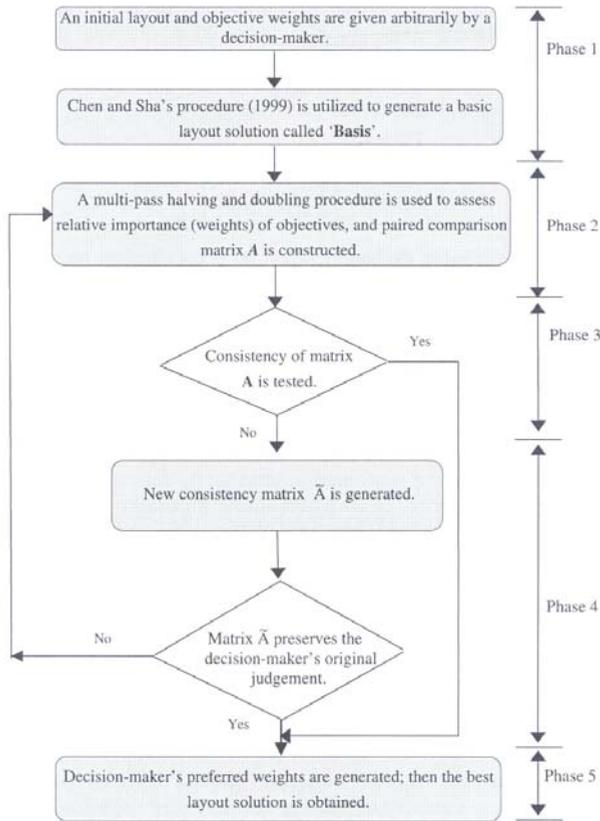


Figura 5.3.7 Heurística de 5 pasos de (Chen y Sha 2005).

Aplica la metodología a un problema QAP monocasilla de 8 actividades basado en el de (Dutta y Sahu 1982), en el que se emplean los siguientes objetivos:

- Cuantitativos: Flujo de materiales, Tiempo de circulación del material.
- Cualitativos: Índice de cercanía, Movimientos peligrosos.

Khilwani et al

En (Khilwani, Shankar y Tiwari 2008) se propone una nueva metodología para la afrontar el problema, explotando varias técnicas diferentes en cada una de las fases de resolución del FLP. Los autores trabajan con geometría continua, y con *block layout*, es decir no afrontan el problema con una formulación QAP monocasilla como hemos visto anteriormente. La posición de las actividades no está restringida y se coloca en primer lugar una actividad central, para recorrer el perímetro posteriormente con el resto de actividades.

Tienen en cuenta en su propuesta 3 objetivos todos ellos cuantitativos: flujo de materiales, flujo de personal y flujo de equipamientos. En el modelo teórico también proponen emplear el flujo de personal y los vínculos de supervisión.

Se formula una función objetivo (M1) que minimizar:

$$M1 = \sum_{i=1}^n \sum_{j=1}^n AR_{ij} \cdot d_{ij} \quad (5.36)$$

Donde AR_{ij} es la relación entre las actividades i - j y en ella se integran todos los objetivos enumerados anteriormente, ya sean cuantitativos o cualitativos. La integración de todos objetivos se realiza mediante lógica borrosa.

Para determinar el orden inicial de colocación de las actividades, se listan todas ellas atendiendo a su índice de cercanía total (TCR), las actividades que tengan un mayor índice se situaran en el centro de la solución:

$$TCR_i = \sum_{i,j=1}^n AR_{ij} \quad (5.37)$$

Los pasos que se siguen en la metodología se pueden agrupar en tres fases:

1. *Obtención de información:* Se plantea el problema con los objetivos a un panel de expertos (DM_i), recopilando la información sobre la importancia de objetivos sobre cada par de actividades. La opinión de los expertos se traduce en una serie de relaciones de preferencia multiplicativa (MPR_i), a través de unas funciones de transformación que normalizan los valores de los distintos objetivos. Los valores de los pesos que se emplearán para agregar los objetivos en la función objetivo (en el valor de AR_i) se obtienen mediante lógica borrosa.
2. *Agregación:* Se calcula un MPR global por agregación de los MPR individuales de cada experto mediante un operador OWA (*Ordered Weighted Averaging*), mediante el que los pesos se multiplican por una serie de pesos para obtener un valor final y único.
3. *Explotación:* Se genera un ranking de actividades en función de su conexión con otras. Finalmente se van colocando de las actividades con menor ranking (se sitúan en la periferia) a las de mayor ranking (que se sitúan en el centro). Dado que este proceso es complejo, se emplea una heurística para mejorar los resultados. En este caso se emplea un algoritmo evolutivo, denominado *Psychoclonal Algorithm*.

Los autores aplican la metodología a un problema de 5 actividades de área desigual, propuesto en (Dweiri y Meier 1996). Comparan los resultados obtenidos con los de Dweiri y Deb, y además implementan un algoritmo genético y una técnica de CSA (*Chaos Simulated Annealing*) para comprobar la eficiencia de la heurística del *Psychoclonal Algorithm* que proponen.

Singh y Singh

La última publicación relativa al problema multiobjetivo de distribución en planta es la de (Singh y Singh 2009), en ella los autores realizan una aproximación al problema con una formulación QAP monocasilla, y teniendo en cuenta cuatro objetivos, dos cualitativos (índice de cercanía y movimientos peligrosos) y dos cuantitativos (MHC y MHT).

Emplean una función objetivo aditiva ponderada, con los valores de los objetivos normalizados y con pesos para cada uno de ellos, en concreto, para el caso de 4 objetivos, la función sería la siguiente:

$$m_{ijkl} = w_1 \cdot f_{ij} \cdot d_{kl} - w_2 \cdot cr_{ij} + w_3 \cdot mht_{ij} + w_4 \cdot hm_{ij} \tag{5.38}$$

Donde w_u son los pesos de cada uno de los objetivos

Los autores proponen una heurística de 3 fases para conseguir optimizar el problema QAP, estas tres fases son:

1. *Normalización de las matrices de datos:* En esta primera fase se realiza la normalización de los datos de las matrices de flujo, índice de cercanía... para ello se divide cada elemento de la matriz (E_{iju}) por el sumatorio de todos los elementos de la misma, obteniendo una nueva serie de matrices normalizadas ($u=1...m$), a la que los autores llaman E'_{iju} .
2. *Obtención de los pesos de cada uno de los objetivos.* Plantean cuatro métodos para calcular los pesos de los objetivos.
 - *MWM (método de la media).* Se resuelven tantos problemas como objetivos se tengan y después de obtener los mínimos de cada uno de ellos ($f_u(X)_n$), se calcula el peso de cada objetivo como el valor mínimo del objetivo entre la suma de los valores del resto de objetivos.

$$w_u = \frac{f_u(X)_n}{\sum_{u=1}^m f_u(X)_n} \tag{5.39}$$

- *GMWM (método de la media geométrica).* El método es similar al anterior, con la diferencia de que se calcula no el valor mínimo de cada objetivo, sino la media geométrica para cada objetivo. En el caso en el que las matrices de datos sean simétricas:

$$G_u = \sqrt[n]{\prod_{i=1}^{n-1} \prod_{\substack{j=i+1 \\ i \neq j}}^n |E'_{iju}|} \quad \forall u=1\dots m \text{ con } n'=n \cdot (n-1)/2 \quad (5.40)$$

Una vez obtenido el valor para cada objetivo u, se obtiene el valor medio de cada uno de los pesos:

$$w_u = \frac{G_u}{\sum_{u=1}^m G_u} \quad \forall u=1,\dots,m \quad (5.41)$$

- *SDWM (método de la desviación típica)*. Se obtienen los pesos a través del cálculo de la desviación típica de cada uno de los valores de las matrices de objetivos:

$$\sigma_t = \sqrt{\frac{\sum_{i=1}^{n-1} \sum_{\substack{j=i+1 \\ i \neq j}}^n (|E_{ijt}| - |\bar{E}_{ijt}|)}{(n'-1)}} \quad \forall t=1\dots T \text{ con } n'=n \cdot (n-1)/2 \quad (5.42)$$

Una vez obtenido el valor para cada objetivo t, se obtiene el valor medio de cada uno de los pesos:

$$w_t = \frac{\sigma_t}{\sum_{t=1}^T \sigma_t} \quad \forall t=1,\dots,T \quad (5.43)$$

- *CRITICM (método de la importancia crítica de la correlación entre criterios)*. En este método se emplea como valor de referencia la correlación entre objetivos, para ello, se calcula primero la correlación entre los objetivos (t y u) de la siguiente forma:

$$r_{tu} = \frac{\sum_{i=1}^{n-1} \sum_{\substack{j=i+1 \\ i \neq j}}^n [(|E'_{ijt}| - |\bar{E}'_{ijt}|)_t \cdot (|E'_{ijt}| - |\bar{E}'_{ijt}|)_u]}{(n'-1) \cdot \sigma_t \cdot \sigma_u} \quad \forall t=1,\dots,m \quad (5.44)$$

Para después determinar el valor de correlación de cada objetivo:

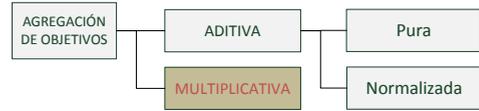
$$C_t = \sigma_t \cdot \sum_{\substack{u=1 \\ t \neq u}}^m (1 - r_{tu}) \quad \forall t=1,\dots,m \quad (5.45)$$

Y finalmente el valor de los pesos de la misma forma que se realizó en apartados anteriores:

$$w_t = \frac{C_t}{\sum_{t=1}^m C_t} \quad \forall t=1, \dots, m \quad (5.46)$$

3. *Optimización de la función objetivo con los pesos anteriores.* Por último los autores proponen resolver de manera independiente el problema FLP con los 4 vectores de pesos y quedarse con el menor de los valores resultantes. Para ello emplean un software de programación lineal (LINGO 8) con el que resuelven los 4 problemas.

5.3.1.2 Función objetivo agregada multiplicativa



Una segunda forma de realizar la agregación de los objetivos en una sola función es hacerlo mediante una función multiplicativa, en la que los distintos objetivos se multiplican (o dividen), sin necesidad de ponderación entre ellos.

En estos casos, la función objetivo m_{ijkl} adopta la siguiente forma genérica para cada uno de los m objetivos:

$$m_{ijkl} = \prod_{u=1}^m f_{ijkl,u} \tag{5.47}$$

Donde: $f_{ijkl,u}$ Es el valor del objetivo u -ésimo.

En la bibliografía solo encontramos tres referencias que empleen esta formulación para resolver el problema, aunque son de un gran interés, como veremos a continuación:

| | | |
|--------------------------|----------------|----------------------|
| (Fortenberry y Cox 1985) | (Islrier 1998) | (Wang, Hu y Ku 2005) |
|--------------------------|----------------|----------------------|

Fortenberry y Cox

La aparición del artículo (Fortenberry y Cox 1985) marca un hito en el campo de la optimización multiobjetivo del problema de distribución en planta, porque emplea una función objetivo multiplicativa que minimiza los objetivos (MHC y CR).

La formulación del problema es idéntica a la de Rosenblatt, la del QAP generalizado monocasilla, solo que cambia la función en la que se relacionan los objetivos $m_{ijkl} = a_{ijkl} \cdot w_{ijkl}$, donde a_{ijkl} es el coste derivado del transporte de materiales y w_{ijkl} el coste de intensidad relacional entre las actividades, formulado de manera diferente que en los artículos anteriores, pues en este caso los autores tienen en cuenta el índice de cercanía (CR o r_{ij}) independientemente de la ubicación relativa de las mismas.

$$m_{ijkl} = a_{ijkl} \cdot w_{ijkl} = (f_{ij} \cdot c_{ij} \cdot r_{ij}) \cdot d_{kl} \tag{5.48}$$

Los valores de transformación del índice de cercanía son diferentes a los empleados en Roseblatt o Dutta, tal y como se muestra en la Tabla 5.3.3.

| | A | E | I | O | U | X |
|------------------|---|---|---|---|---|----|
| Rosenblatt,Dutta | 6 | 5 | 4 | 3 | 2 | 1 |
| Fortenberry | 5 | 4 | 3 | 2 | 1 | -1 |

Tabla 5.3.3 Valores de transformación para r_{ij} .

Esta formulación presenta varios problemas:

1. Las actividades que tengan una relación X con cualquiera del resto de actividades serán muy penalizadas sea cual sea el flujo de materiales entre ellas.
2. Los pares de actividades que no tengan flujo interdepartamental, no influyen en el valor de m_{ijkl} , por tanto no se tienen en cuenta a la hora de calcular el valor final. Un par de actividades i-j que tengan un $r_{ij}=-1$ y un flujo $f_{ij}=0$ pueden tener una frontera común (algo no deseable) y no estar penalizando la función m_{ijkl}

Para la optimización utiliza un algoritmo similar al de Dutta, en el que a partir de una solución inicial generada aleatoriamente va realizando intercambios de actividades, aceptando los que provocan un descenso de la función objetivo.

Es un algoritmo que presenta los mismos problemas que aquel, pues es un *steepest descent* y se bloquea en óptimos locales. Aplica el algoritmo a los problemas empleados por Dutta (6 y 8 actividades) y un nuevo problema de 12 actividades, comparando los resultados con los artículos previos.

Islier

Hasta 13 años después no aparece el siguiente modelo multiplicativo, y es en (Islier 1998) donde se presenta una formulación multicriterio con agregación multiplicativa para el problema de distribución en planta y resuelve la optimización mediante el uso de algoritmos genéticos.

La formulación matricial propuesta, considera tres factores: un factor de carga (t), un factor de forma (s) y un factor de desviación (h), combinados en una función agregada multiplicativa que maximiza.

El modelo planteado por Islier se formula como:

$$\text{Max } \left(\frac{t}{s \cdot h} \right) \quad (5.49)$$

s.t.

$$\begin{aligned} \sum_{k=1}^n a_{ijk} &\leq 1 && \forall i, j \\ \frac{A_k}{a} &\leq \sum_{i=1}^a \sum_{j=1}^h a_{ijk} \leq \overline{A_k} && \forall k \\ \sum_{i=1}^a \sum_{j=1}^h \sum_{k=1}^n a_{ijk} &\leq a \cdot h \end{aligned} \quad (5.50)$$

La primera restricción evita la superposición de actividades ($a_{ijk}=1$ si la actividad k está en la posición ij -ésima), la segunda controla que el área de una actividad esté entre los límites admisibles inferior y superior, por tanto se permite introducir actividades con holgura (en esta restricción a es el número de filas y h el número de columnas) y la tercera limita el número de celdas ocupadas a las disponibles en el recinto ($a \cdot h$).

Veamos cada uno de los factores que intervienen en la formulación de Islier y qué papel juegan en la misma:

1. *Factor de carga (t)*. Este factor está relacionado con el coste de manutención, y queda definido como:

$$t = \frac{V}{\sum_{i=1}^{n-1} \sum_{j=2}^n c_{ij} \cdot f_{ij} \cdot d_{ij}} \quad (5.51)$$

Donde: V Es la carga ideal de trabajo y se obtiene mediante el producto escalar de las matrices de distancias entre casillas (ordenada de menor a mayor) y la matriz de flujos (ordenada de mayor a menor), para el caso del problema monocasilla.

n es el número de actividades.

c_{ij} es el coste de manutención por unidad de distancia entre las actividades i y j .

f_{ij} es el flujo de material entre las actividades i y j por unidad de tiempo.

d_{ij} es la distancia rectilínea entre las actividades i y j .

Este factor siempre adquiere un valor en el intervalo $[0,1]$, cuanto mayor sea t , la carga de trabajo se acercará más a la ideal, cuya cota superior será precisamente esa carga ideal (V).

2. *El factor de forma (s)*. Mide la concentración de la geometría de una actividad y se formula:

$$s = \frac{\sum_{k=1}^n r_k}{\sum_{i=1}^a \sum_{j=1}^h \sum_{k=1}^n a_{ijk}} \quad (5.52)$$

- Donde: a_{ijk} : variable de asignación que es igual a 1 si las celdas i,j están ocupadas por la actividad k (y 0 en caso contrario)
- a : Número de filas de la discretización del dominio.
- h : Número de columnas de la discretización del dominio.
- r_i : El momento de inercia del área de la i -ésima actividad.
- u_{pk} : Distancia rectilínea del cdg de la actividad k al centro de la celda p .

$$r_k = \sum_{p \in S_k} u_{pk}^2 \quad (5.53)$$

Este factor se introduce para evitar la dispersión de las casillas de la actividad, al disponerlas sobre el dominio de la planta. Cuanto menor sea el valor de s , menor es la dispersión global de las actividades.

3. *El factor de desviación (h)*. Este factor mide la utilización efectiva del espacio, pues como se comentó anteriormente se permite una cierta holgura en lo relativo a las áreas de las actividades y se formula:

$$h = 1 - \frac{\sum_{k=1}^n A_k - \sum_{i=1}^a \sum_{j=1}^h a_{ijk}}{\sum_{i=1}^a \sum_{j=1}^h \sum_{k=1}^n a_{ijk}} \quad (5.54)$$

Donde: A_k es el área de la actividad k .

Por tanto, el planteamiento de Islier no tiene en cuenta objetivos cualitativos, sino que todos son cuantitativos (Flujo, Forma y Desviación). El dominio es discreto y las actividades se pueden introducir con holgura, de ahí la introducción de un indicador de dispersión (h). El relleno se realiza mediante una técnica oscilatoria ALDEP, con banda variable y la métrica empleada para calcular las distancias es la Euclídea.

La metodología se aplica sobre dos problemas test de 12 y 15 actividades de (Banerjee et al. 1992), calculando los valores de la función objetivo propuesta para las mejores soluciones, y obteniendo nuevos óptimos con la nueva formulación.

Wang, Hu y Ku

(Wang, Hu y Ku 2005), presentan una formulación multicriterio con agregación multiplicativa para el problema de distribución en planta y resuelve la optimización mediante el uso de algoritmos genéticos.

Esta formulación es una variación de la de (Islier 1998) y considera tres criterios cuantitativos, como son: factor de coste de mantenimiento (MFCC, similar al MHC), factor de forma de la configuración (SRF_{config}) y un factor de utilización del área total (AUF_{config}). Todos ellos son combinados en una función agregada multiplicativa (a la que llama "idoneidad") que posteriormente maximiza. La expresión de la función objetivo es la siguiente:

$$\text{Max } \frac{1}{\text{TLC}} = \frac{1}{\text{MFCC}} \cdot \frac{\text{AUF}_{\text{config}}}{\text{SRF}_{\text{config}}} \quad (5.55)$$

s.t.

$$\begin{aligned} \sum_{k=1}^n a_{ijk} &\leq 1 && \forall \text{ posición } i, j \\ \sum_{i=1}^a \sum_{j=1}^h a_{ijk} &\leq A_k && \forall \text{ actividad } k \\ \sum_{i=1}^a \sum_{j=1}^h \sum_{k=1}^n a_{ijk} &\leq a \cdot h \end{aligned} \quad (5.56)$$

Donde: TLC Coste total de la distribución.

$a_{ijk}=1$ Si la posición i, j está ocupada por la actividad k (0 sino).

A_k Área requerida por la actividad k .

a Número de columnas del dominio.

h Número de filas del dominio.

Veamos cómo se define cada uno de los factores que intervienen en la función objetivo.

1. *Factor de forma SRF.* Para calcular el factor de forma de la configuración SRF, debemos determinar el ratio de forma (SR_k) de cada una de las actividades, como:

$$\text{SR}_k = \frac{P_k}{4\sqrt{A_k}} \quad (5.57)$$

de tal forma que el factor de forma para una configuración dada (SRF_{config}) se expresa como:

$$\text{SRF}_{\text{config}} = \left(\prod_{k=1}^n \frac{P_k}{4\sqrt{A_k}} \right)^{1/n} \quad (5.58)$$

| | |
|------------|---------------------------------|
| Donde: n | Número de actividades. |
| P_k | Perímetro de la actividad k . |
| A_k | Área de la actividad k . |

2. *Factor de utilización AUF.* Se define el factor de utilización del área total, AUF_{config} , como la relación entre el área ocupada y el área disponible en el dominio. Es por tanto un indicador global de la solución, y mide el espacio libre que se deja, siempre que el dominio sea superior al área requerida por todas las actividades.

$$AUF_{config} = \frac{\sum_{k=1}^n A_k}{\sum_{k=1}^n A_k + TBA} \quad (5.59)$$

Donde: $\sum_{k=1}^n A_k$ Es el área requerida por todas las actividades.

TBA Es la suma del área de las casillas no ocupadas por actividad alguna.

3. *Factor de coste de mantenimiento MFFC.* Se define el factor del coste de mantenimiento mediante la siguiente expresión:

$$MFFC = \sum_{i=1}^n \sum_{j=1}^n c_{ij} \cdot f_{ij} \cdot d_{ij} \quad (5.60)$$

Donde: c_{ij} Coste de transportar una unidad de material una unidad de distancia entre las actividades i y j .

f_{ij} Flujo entre las actividades i y j .

d_{ij} Distancia rectilínea entre los centroides de las actividades i y j .

Los autores resuelven el problema de distribución en planta con actividades de área desigual, utilizan un dominio finito, que se discretiza y sobre él se realiza la construcción mediante una curva de relleno (SFC).

Se fijan diferentes dimensiones del dominio y se emplea un análisis de la varianza, tipo ANOVA para determinar cuál es la dimensión óptima del dominio. Todo ello sobre los problemas de (Tompkins y White 1984) y (Armour y Buffa 1963) de 8, 12 y 20 actividades.

5.3.2 Métodos basados en frontera de Pareto

Una aproximación totalmente distinta a la comentada en apartados anteriores es considerar el problema de distribución en planta multiobjetivo desde el punto de vista de un conjunto de soluciones eficientes, o frontera de Pareto. En este caso no se busca un único valor como óptimo al problema (ya sea local o absoluto) sino un conjunto de valores que son eficientes, es decir que bajo uno o más objetivos son mejores que el resto.



Figura 5.3.8 Métodos basados en frontera de Pareto.

El concepto de óptimo de Pareto ya se explicó en capítulos anteriores y es ésta aproximación la que el siguiente conjunto de referencias realizan al problema:

| | | | |
|-----------------------------------|------------------|------------------------|------------------------------|
| (Rosenblatt y Sinuany-Stern 1986) | (Malakooti 1989) | (Raoot y Rakshit 1993) | (Tuzkaya, Ertay y Ruan 2005) |
| (Aiello, Enea y Galante 2006) | (Ye y Zhou 2007) | (Sahin y Türkbey 2009) | |

En este caso no tiene sentido hablar de una función objetivo, pues la optimización no se realiza atendiendo a un único valor resultante de la combinación de los objetivos, sino que en cada caso hay que ver si el punto entra a formar parte de la frontera de Pareto o no, para así aceptarlo.

Algunas de las referencias mencionadas combinan la aproximación como frontera de Pareto con un proceso posterior de selección de alternativas, en todos los casos con ELECTRE, para determinar qué solución de la frontera es la óptima.

La primera publicación que trato el problema desde un punto de vista multiobjetivo (Rosenblatt 1979) ya hablaba de un conjunto de soluciones eficientes, de algunas soluciones dominadas, aunque el tratamiento que se daba al proceso de optimización no era de conjunto de Pareto, pues se agregaban los objetivos para obtener directamente una solución óptima, por esta razón la he colocado en el grupo de aproximaciones mediante funciones objetivo aditivas. Aunque es de destacar que en esta primera publicación ya se hiciera hincapié en el concepto de conjunto de soluciones eficientes.

Rosenblatt y Sinuany-Stern

En (Rosenblatt y Sinuany-Stern 1986), los autores continúan el trabajo previo, introduciendo el término de “Discrete Efficient Frontier (DEF)”, que es análogo a la frontera de Pareto definida en apartados anteriores.

Establece una regla de dominación que formula de la siguiente manera. Si ordenamos las soluciones que pertenecen a la DEF, según uno de los criterios (por ejemplo el MHC, al que llama C) en orden descendente ($C_i \leq C_{i+1}$), entonces para cualquier valor de α , la solución i es dominada por otras soluciones si:

$$\frac{R_i - R_{i-1}}{C_i - C_{i-1}} < \frac{R_{i+1} - R_i}{C_{i+1} - C_i} \tag{5.61}$$

Esta segunda regla de dominación elimina soluciones que nunca son óptimos (no existe ningún valor de α que haga que el valor de la función objetivo sea mínimo entre todas las soluciones). Esta regla hace que valores como el punto i de la Figura 5.3.9 queden excluidos de la DEF, aunque no sean puntos dominados por la primera regla.

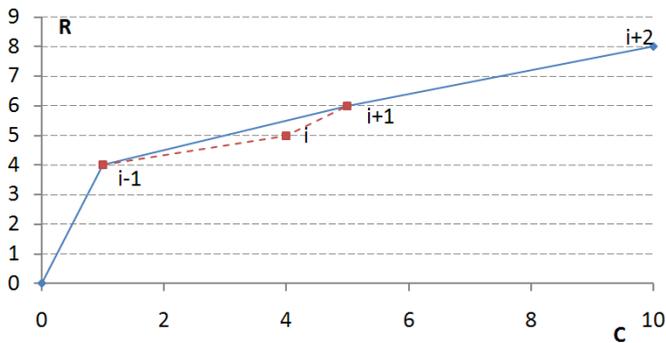


Figura 5.3.9 Punto dominado con la 2ª regla de dominación de Rosenblatt.

Los autores proponen una expresión para determinar en qué rangos de los pesos α , es cada solución la dominante, para la solución i sería la siguiente.

$$\alpha_i = \frac{R_i - R_{i-1}}{R_i - R_{i-1} + C_i - C_{i-1}} \tag{5.62}$$

En esta referencia, no se realiza una aplicación directa sobre el problema de distribución en planta multiobjetivo, aunque sí que es mencionado como problema de referencia.

El objetivo fundamental del artículo es realizar la depuración de la frontera de Pareto, por tanto no se realiza ni construcción ni mejora.

Malakooti

En (Malakooti 1989) se establece la primera referencia del problema de FLP como un problema multiobjetivo en términos del conjunto eficiente de Pareto, aunque sin nombrarlo específicamente.

Las aportaciones de ésta referencia son cruciales en dos aspectos, por un lado establece una clasificación de las metodologías con las que se aborda el problema FLP multiobjetivo que será citada por numerosos autores posteriores y que se ha comentado en apartados anteriores de este trabajo, y en segundo lugar, porque es el primer autor que habla de un conjunto de soluciones eficientes (que conformaran la frontera de Pareto).

El autor hace una crítica de los modelos basados en funciones de agregación aditivas, pues pueden aparecer algunos problemas que tienen que ver con los valores de los pesos, si estos son fijos, ya que únicamente se generarán soluciones que (en el caso de un problema bicriterio) estén en la recta: $z = w_1 \cdot f_1 + w_2 \cdot f_2$, no siendo posible generar soluciones que, pese a ser mejores no se encuentran en esa recta (la solución B es tan válida como las soluciones A,C y D).

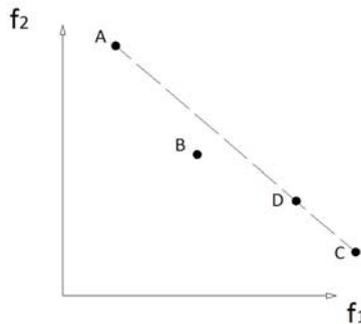


Figura 5.3.10 Riesgo de no generación de soluciones válidas, de (Malakooti 1989).

El autor también clasifica la forma en la que se puede formular el problema multiobjetivo:

- Como un *QAP multiobjetivo*, con tantas funciones como objetivos tenga el problema (es lo que llamamos en este trabajo un enfoque Pareto del problema).
- Como un *QAP monobjetivo*, con una sola función objetivo en la que se agregan (ponderados y normalizados), todos los objetivos.

El autor acuña el término configuración *localmente eficiente*, que es aquella solución que es eficiente respecto a todas sus configuraciones adyacentes (una configuración X_{n+1} es adyacente a una configuración X_n , si se obtiene intercambiando dos actividades, o como comentamos en el presente trabajo $n+1$ está en la vecindad de n).

Además propone una heurística que está muy cerca del planteamiento de frontera de Pareto, pues aplica su metodología al problema de 9 actividades (monocasilla) enunciado

en (Malakooti y D'Souza 1987), de la siguiente forma: genera todas las soluciones del problema ($9!=362880$), de ellas extrae todas las soluciones eficientes frente a los 3 objetivos (MHC, tiempo de flujo de materiales y flexibilidad), que resultan ser 111 configuraciones “realmente eficientes”.

A continuación genera 5 combinaciones de pesos de cada uno de los 3 objetivos, y genera soluciones aleatorias con cada uno de ellos, para después plantear el problema en términos de eficiencia local. Genera las soluciones de la vecindad y va agregando soluciones al conjunto de soluciones eficientes. De esta manera procede con las 5 combinaciones de pesos y obtiene un conjunto de soluciones “localmente eficientes” de 102 configuraciones, de las que únicamente una de ellas es dominada por soluciones “realmente eficientes”.

El planteamiento de Malakooti es afrontar el problema por una búsqueda por entornos, y la aleatoriedad de los pesos permite explorar una amplia zona del espacio de soluciones.

Raoot y Rakshit

En el artículo (Raoot y Rakshit 1993), los autores proponen una metodología multicriterio en la que emplean una técnica de lógica difusa basada en “diseño lingüístico”, mediante el que se genera un conjunto de alternativas eficientes, que después se seleccionan mediante una metodología ELECTRE.

Los objetivos que emplean son:

- Coste de transporte de materiales.
- Indicadores de cercanía: Facilidad del personal, Facilidad de supervisión y seguridad.

La técnica sitúa las actividades en un determinado orden y posteriormente evalúa la calidad de la alternativa mediante el valor normalizado de MTV (*Mean Truth Value*) que debe ser maximizado entre actividades, lo que da lugar a una matriz (*Truth Value Matrix*).

No emplea ninguna heurística específica de mejora, sino que propone el intercambio manual de dos actividades y la comparación de ambas, empleando el término de **Eficiencia de una solución**, empleando una técnica Pareto para decidir si la solución es o no es eficiente respecto al resto, y por tanto entra a formar parte de la frontera de Pareto.

En una fase posterior del proceso, se determina qué solución del conjunto de las eficientes es la solución óptima mediante una técnica ELECTRE. La metodología propuesta se aplica a un ejemplo de 8 actividades de (Tompkins 1978), el relleno de las actividades se hace mediante una técnica continua tipo *Flexbay*.

En (Tuzkaya, Ertay y Ruan 2005) aparece por primera vez una aproximación al problema de distribución en planta mediante un algoritmo basado en MOSA (Optimización Multiobjetivo con *Simulated Annealing*).

Los autores plantean una técnica basada en el algoritmo UMOSA, que se describe en el capítulo 2 del presente trabajo y que acepta soluciones parcial o totalmente negativas con una probabilidad de transición baja, por lo que es capaz de salir de mínimos locales.

En concreto, esta técnica contempla tres situaciones diferentes, en las que se adoptan tres estrategias frente a la decisión de pasar a la solución generada. Las tres situaciones son diferentes en función de que supone pasar de la solución actual (X_n) a la generada (X_{n+1}):

- Situación 1: Mejora de todos los objetivos. Utiliza siempre la estrategia 1.
- Situación 2: Mejora de algún objetivo y el empeoramiento de otros. Puede decidir utilizar la estrategia 1, 2 o 3.
- Situación 3: Empeoramiento de todos los objetivos. Utiliza la estrategia 3.

Las tres estrategias a seguir son las siguientes:

- Estrategia 1: Aceptar la nueva solución (X_{n+1}) con una probabilidad $p=1$.
- Estrategia 2: La probabilidad de aceptar la nueva solución (X_{n+1}) se calcula con una “aproximación escalarizante de objetivos”.

En realidad lo que se propone en esta estrategia es calcular el valor de la solución actual y la propuesta mediante una función objetivo ponderada aditiva (a la que llama $S(Z, \lambda)$), calculando después el valor del incremento de esa función (Δs):

$$s(Z, \lambda) = \sum_{k=1}^m \lambda_k \cdot z_k \tag{5.63}$$

$$\sum_{k=1}^m \lambda_k = 1 \quad \text{con } \lambda_k > 0 \quad \forall k$$

Donde k es cada uno de los m objetivos y λ_k es el peso del objetivo k -ésimo, posteriormente, la probabilidad de transición a la nueva solución será:

$$p = \begin{cases} 1 & \text{si } \Delta s \leq 0 \\ e^{(-\Delta s / T_n)} & \text{si } \Delta s > 0 \end{cases} \tag{5.64}$$

Donde: T_n es la temperatura en el escalón de temperatura n -ésimo.

- Estrategia 3: La probabilidad de aceptar la nueva solución (X_{n+1}) se calcula con una “aproximación escalarizante de la probabilidad”.

En este caso para calcular la probabilidad de transición a una solución peor desde todos los objetivos, se debe determinar el valor del incremento en cada uno de los k criterios (Δz_k), para determinar después el valor de π_k de la siguiente expresión:

$$\pi_k = \begin{cases} e^{(-\Delta z_k / T_n)} & \text{si } \Delta z_k > 0 \\ 1 & \text{si } \Delta z_k \leq 0 \end{cases} \quad (5.65)$$

Una vez realizado para los m criterios, se agregan, empleando una de las dos expresiones siguientes:

$$p = \prod_{k=1}^m (\pi_k)^{\lambda_k} \quad (5.66)$$

$$p = \min(\pi_k)^{\lambda_k} \quad (5.67)$$

Donde T_n es la temperatura en el escalón de temperatura n -ésimo.

Los objetivos empleados son el coste derivado del flujo de materiales (MHC) así como la adyacencia entre actividades. Toda esta formulación la aplica a un ejemplo propio de 10 actividades de área desigual, con un relleno continuo.

Aiello et al

En (Aiello, Enea y Galante 2006) encontramos una nueva aproximación problema de distribución en planta multiobjetivo de actividades con áreas desiguales, desde el punto de vista del óptimo de Pareto.

Los autores plantean el problema multiobjetivo con la finalidad de encontrar una frontera de Pareto y a partir de ella y mediante una técnica ELECTRE, determinar la solución óptima, tal y como hacían (Raoot y Rakshit 1993).

Los objetivos que se plantean son los siguientes:

- *Cuantitativos*: MHC (flujo de materiales entre actividades) y un *Aspect Ratio* de cada una de las actividades.
- *Cualitativos*: Adyacencia (cuantificada a partir de un índice de cercanía, r_{ij}) y Distancia Requerida (cuantificada a través de un índice de distancia, s_{ij}).

Emplean un modelo geométrico continuo tipo *flexbay*, y como heurística de optimización emplea algoritmos genéticos (NSGA-II). Todo ello lo aplican a un ejemplo propio de 20 actividades sobre el que aplica la metodología.

Ye y Zhou

En su artículo (Ye y Zhou 2007) plantean una nueva heurística híbrida entre algoritmos genéticos y Tabú Search (GATS) para la optimización del problema, que se aborda en su vertiente de actividades de diferente tamaño y con pasillos.

Los objetivos que emplean los autores son el flujo de materiales (MHC) y el índice de cercanía de las actividades (CR), como en la mayor parte de las referencias anteriores.

La metodología se aplica sobre un ejemplo propio de 11 actividades de diferente área, con un recinto con pasillos y dimensiones fijos, aplicando también optimización multiobjetivo con *Annealing* (MOSA) y con *Tabú Search* (MOTS), generando 3 fronteras de Pareto con cada una de las técnicas de optimización.

Sahin y Türkbey

En (Sahin y Türkbey 2009) encontramos una aproximación muy reciente al problema de distribución en planta de procesos industriales basado en el conjunto eficiente de Pareto con una heurística de SA, que es precisamente la planteada en éste trabajo.

Los autores plantean el problema QAP monocasilla atendiendo a los dos objetivos clásicos, como son el coste de transporte de materiales (MHC) y el índice de cercanía de actividades (CR), que tal y como se ha comentado en toda la bibliografía descrita son un criterio cuantitativo (MHC) y otro cualitativo (CR).

Los autores formulan el problema con dos funciones objetivo independientes (lo que en (Malakooti 1989) se denomina Problema I) de las que va obteniendo valores para después combinarlos en una función aditiva ponderada que utiliza en el proceso de optimización mediante SA. Cada uno de los dos objetivos se cuantifican por separado y luego se suman multiplicados por unos pesos w_1 y w_2 . Uno de los aspectos menos claros del artículo es cómo determinan los valores de esos pesos y como se formula esa función aditiva, pues los criterios son antagónicos, por tanto lo más probable es que el valor de E se obtenga:

$$E_{II} = w_1 \cdot E_{\text{cost}} - w_2 \cdot E_{\text{closeness}} \quad (5.68)$$

El valor de la función objetivo aditiva ponderada E, se utiliza como referencia a la hora de determinar si se acepta una nueva solución, en el criterio de aceptación del *Simulated Annealing*. Se determina el valor de la distancia existente entre la solución actual y la mejor solución existente (o solución de referencia, que es aquella con un menor valor de la función objetivo E_c):

$$\Delta E = E_{II} - E_c \quad (5.69)$$

Si $\Delta E \leq 0$ la solución es mejor que la solución de referencia, con lo cual entra en el conjunto de Pareto, y pasa a ser la nueva solución de referencia. Si $\Delta E > 0$, la solución no forma parte del conjunto de Pareto y se aceptará con una probabilidad de transición $p = e^{-\Delta E/T}$.

Los autores plantean una heurística similar a la establecida en el presente trabajo y que será discutida en apartados posteriores, la misma es aplicada a una serie de problemas QAP monocasilla de 6, 8, 12, 15, 20 y 30 actividades recogidos de (Fortenberry y Cox 1985) y (Suresh y Sahu 1993) y comparados con soluciones obtenidas en las referencias que se han ido comentando en el estado del arte de este trabajo. Obtienen las fronteras de Pareto de cada uno de los problemas, que están formadas por un número variable de puntos, algunos de ellos históricos y otros determinados por los autores. Todos los datos se resumen en la siguiente tabla:

| Nº Activ. | Referencia | Nº Soluciones en cjto. Pareto | Nº Soluciones históricas | Nº Soluciones aportadas |
|-----------|--------------------------|-------------------------------|--------------------------|-------------------------|
| 6 | (Fortenberry y Cox 1985) | 4 | 2 | 2 |
| 8 | (Fortenberry y Cox 1985) | 5 | 3 | 2 |
| 12 | (Fortenberry y Cox 1985) | 20 | 1 | 19 |
| 12 | (Suresh y Sahu 1993) | 20 | 7 | 13 |
| 15 | (Suresh y Sahu 1993) | 23 | 1 | 22 |
| 20 | (Suresh y Sahu 1993) | 29 | 1 | 28 |
| 30 | (Suresh y Sahu 1993) | 33 | 2 | 31 |

Tabla 5.3.4 Soluciones de (Sahin y Türkbey 2009).

De todas las referencias bibliográficas comentadas en el presente capítulo, muy pocas emplean objetivos geométricos, únicamente lo hacen cuatro: (Logendran y Kriausakul 2006), (Deb y Bhattacharyya 2003), (Islir 1998) y (Wang, Hu y Ku 2005). Todas las aproximaciones emplean el coste entre actividades como uno de sus objetivos, acompañándolo en el mayor número de casos de un indicador de cercanía (ya sea de forma cualitativa o cuantitativa).

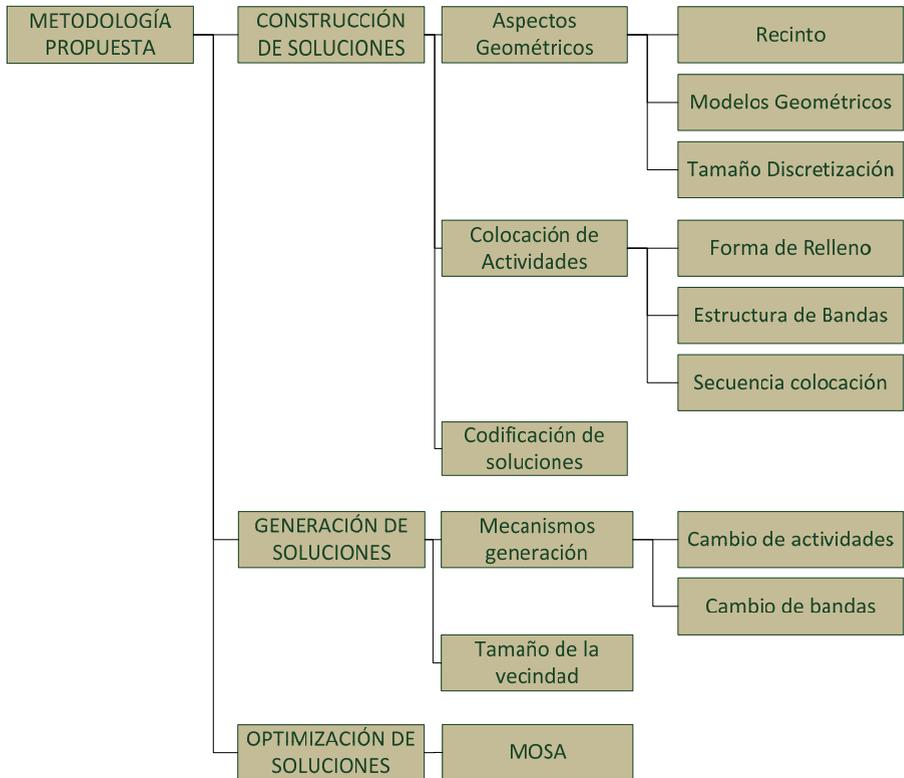
6 METODOLOGÍA PROPUESTA

Una vez visto el problema que se va a abordar, los criterios que se van a considerar y las aproximaciones que al mismo se han realizado en la bibliografía, se procede a establecer los diferentes aspectos a tener en cuenta en lo relativo a la metodología que se empleará para resolver el problema.

En este capítulo se van a describir con detalle todas las cuestiones relativas a:

- La construcción de cada solución.
- El proceso de generación de nuevas soluciones.
- La optimización de las soluciones obtenidas.

En el siguiente esquema se muestran todas las cuestiones que se van a detallar en el presente capítulo, de importancia crucial en la presente investigación. Los ejemplos desarrollados para explicar parcialmente algunos de los puntos se han realizado sobre el problema de 20 actividades propuesto en (Armour y Buffa 1963), aunque son extrapolables a cualquier otro problema de test.



6.1 CONSTRUCCIÓN DE SOLUCIONES

El primer aspecto a fijar en la metodología a emplear en el presente trabajo es todo lo relativo a la construcción de una solución al problema de distribución en planta. A la hora de generar y caracterizar una nueva configuración se deben establecer una serie de parámetros que se pueden englobar en tres grandes grupos:

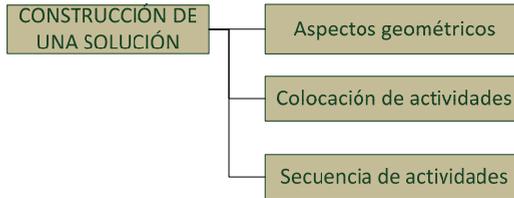


Figura 6.1.1 Aspectos a tener en cuenta en la construcción de una solución.

En el primer grupo de aspectos se recogen todos aquellos que tienen que ver con el recinto sobre el que se va a plasmar la solución, y que deben considerar, entre otras cosas, el tamaño y orientación del recinto, el modelo geométrico empleado, tamaño de la discretización...

Una vez se tiene claro el soporte sobre el cual se va a desarrollar la solución, se deben establecer criterios en lo relativo a la forma en la que se van a colocar las actividades sobre el mismo. Según el modelo geométrico seleccionado, esta etapa será o no necesaria, pues determinados modelos geométricos tienen implícitamente descrito un sistema de colocación de actividades.

Por último se debe conocer la secuencia de colocación de actividades a colocar sobre el soporte, mediante el sistema de colocación por el que se haya optado.

Una vez conocidos todos estos parámetros, se establecerá una codificación que permita nombrar cada una de las configuraciones que se obtendrán en el capítulo de plan experimental de la presente tesis.

6.1.1 Aspectos Geométricos

6.1.1.1 Caracterización del recinto

La primera decisión a tomar al abordar el problema de distribución en planta, y en concreto el problema de 20 actividades de Armour y Buffa, es la relativa al recinto en el que se va a implantar el problema.

El recinto es al problema como el tablero al juego del ajedrez, debe ser descrito con precisión para que el desarrollo del problema sea correcto. En este caso se deben definir aspectos que deben recoger las siguientes características del mismo:

6.1.1.1.1 Tamaño del recinto

La primera decisión a tomar es el tamaño del recinto en el que se va a implantar la solución. Solo hay dos formas de abordar el problema, considerando el recinto estrictamente necesario para ubicar las actividades o bien considerando un recinto con cierta holgura, dejando espacio para una actividad de relleno (*dummy*).

En **3.2.2.3** se reflexionó sobre este punto, y ya se comentó que la práctica totalidad de los autores que han abordado los problemas de Armour y Buffa lo han hecho con un recinto de tamaño estricto, y solo en los casos en los que la forma del recinto se varía y como consecuencia de la discretización queda espacio disponible sin ser asignado a ninguna actividad.

Este caso se produce, por ejemplo en (Wang, Hu y Ku 2005) cuando se emplea un recinto de 12x12 o de 14x10 para albergar el problema de 9 actividades, con un área total de las actividades de 138 unidades. Sin embargo en todas las referencias que emplean el problema de 20 actividades con un modelo geométrico discreto emplean un recinto estricto. Entre las que emplean un modelo geométrico continuo, las únicas que emplean un recinto de mayores dimensiones que las estrictamente necesarias son aquellas que utilizan el esquema ABSMODEL de Heragu.

6.1.1.1.2 Aspectos formales del recinto

La segunda característica a fijar en lo relativo al recinto es la forma en la que se van a configurar las dimensiones del mismo. En el presente trabajo se propone emplear un parámetro R , que recoja por una parte el aspecto formal del recinto, e implícitamente también la orientación del mismo.

El parámetro queda definido por el cociente entre la dimensión horizontal y vertical del recinto:

$$R = \frac{\text{anchura recinto}}{\text{altura del recinto}} \quad (6.1)$$

Esta definición permite fijar la forma del recinto, un valor $R=1$ denota los recintos de forma cuadrada, y cualquier valor diferente de la unidad recintos rectangulares. En la mayor parte de artículos de la bibliografía, se emplean recintos rectangulares, bien con $R=1.5$ o con $R=0.67$, sin embargo en (Wang, Hu y Ku 2005) se estudia la posibilidad de emplear recintos cuadrados (con valores muy cercanos a la unidad), de hecho, la solución con menor coste obtenida es con forma cuadrada (aunque la rectangular está muy próxima).

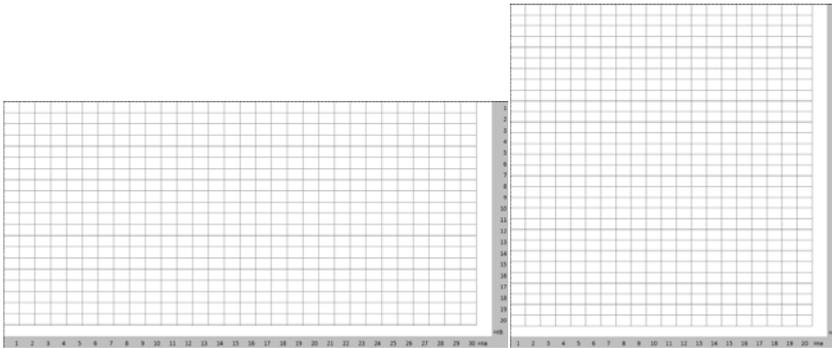


Figura 6.1.2 Dos formas de orientar el recinto $R=1.5$ (i) y $R=0.67$ (d).

El valor de R también proporciona valiosa información de la orientación del recinto, en el caso de formas de recinto rectangulares. En la Figura 6.1.2 se pueden observar los dos casos de diferente orientación de un recinto con idéntica forma. En ambos casos es un recinto de 20×30 unidades de área.

La diferente orientación influye en la forma en la que se realizan los cortes para fijar las bandas de construcción de la solución. Los cortes siempre se realizan de forma vertical, es decir, paralelos al eje Y , tal y como se muestra en la Figura 6.1.3.

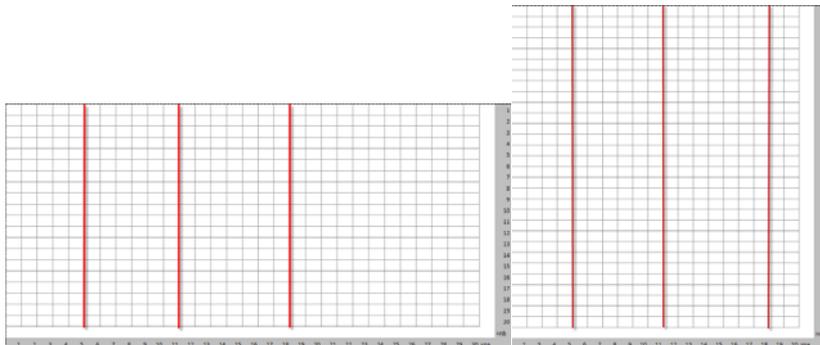


Figura 6.1.3 Configuración de bandas en dos recintos con $R=1.5$ y $R=0.67$.

En las referencias que abordan el problema AB20, hay variedad entre la forma en la que se orienta el recinto, mientras que (Wang, Hu y Ku 2005) y (Gonzalez 2005) emplean una orientación con $R=0.67$, otros autores como (Islir 1998), (Meller y Gau 1996) y (Tate y Smith 1995) emplean $R=1.5$.

Antes de comenzar el trabajo de investigación se realizó un tanteo de las diferentes opciones de tamaño de recinto anteriormente comentadas, para ello se realiza un paseo aleatorio considerando un tamaño de recinto variable entre 0.5 y 2, con la finalidad de observar como varia el coste entre centros de actividades con esta variable. El paseo aleatorio se realiza en base a 35.000 experimentos independiente, arrojando los resultados mostrados en la Figura 6.1.4, en la que se muestra también la línea de tendencia, que tiene un mínimo de coste en una $R=1.14$.

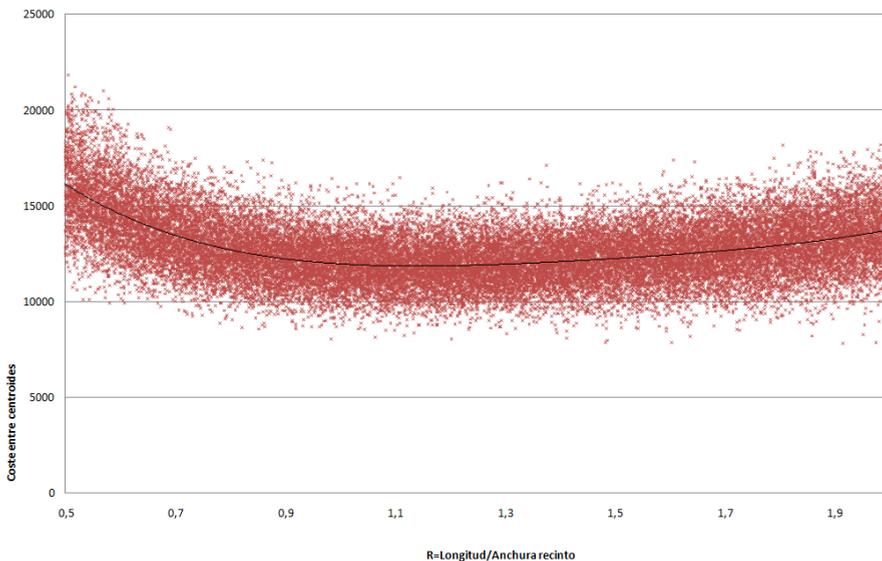


Figura 6.1.4 Paseo aleatorio con tamaño de recinto variable.

En el presente trabajo se opta por orientar el recinto con $R=1.5$, persiguiendo obtener soluciones con una mejor calidad formal, puesto que si la anchura de la banda es muy estrecha, dará lugar a actividades con formas excesivamente alargadas, tal y como se mostrará posteriormente.

6.1.1.2 Modelo geométrico empleado

De entre los modelos expuestos en el capítulo 2, se decide abordar el problema de distribución en planta mediante un modelo geométrico discreto, que frente a los modelos continuos tiene las siguientes ventajas e inconvenientes:

Ventajas

- Este modelo se adapta a recintos de forma irregular.
- Permite la inclusión de zonas inaccesibles o reservadas.

Desventajas

- La calidad formal de las soluciones puede ser inferior.
- Se debe controlar la disgregación de actividades.

6.1.1.3 Tamaño de la discretización

Una vez que se ha decidido utilizar un modelo geométrico discreto, solo resta considerar el tamaño de la discretización que se va a emplear para realizar la colocación de las actividades mediante la curva de relleno que se describirá en apartados posteriores.

En todas las referencias que emplean un modelo geométrico discreto se considera un tamaño de celda igual a 1x1 unidad, por tanto para configurar una actividad de 10 unidades de área bastan 10 casillas de la discretización.

En la única referencia en la que se emplean un tamaño de rejilla diferente es en (Gonzalez 2005), en la que se emplean rejillas de doble resolución (con celdas de 0.5 unidades de área). En la investigación se encontraron algunas mejoras en indicadores concretos, aunque por lo general las soluciones conseguidas con doble resolución eran dominadas por las de resolución sencilla.

Por todo ello y dado que el emplear una rejilla de doble resolución conlleva una mayor complejidad a la hora de construir las soluciones, lo que devenga en un mayor (casi el doble) tiempo de computación para montar cada solución, se opta por considerar una rejilla de simple resolución, con un tamaño de celda de 1 unidad de área.

6.1.2 Colocación de Actividades

6.1.2.1 Formas de realizar el relleno

Una vez conocido el modelo geométrico a emplear en la presente investigación (el discreto), se debe analizar las diferentes opciones para realizar el relleno del mismo, que se pueden resumir en técnicas basadas en ALDEP y las basadas en curvas de relleno (SFC). En el presente trabajo se empleara una técnica híbrida, en la que la colocación se realizará mediante una SFC guiada, para poder cubrir el recinto en su totalidad sin que se produzcan roturas de las actividades.

6.1.2.1.1 ALDEP

La primera posibilidad para realizar el relleno del recinto discretizado mediante la técnica ALDEP, descrita por (Seehof y Evans 1967), en la que se realiza un barrido del recinto mediante un relleno oscilatorio, que puede ser, tal y como se muestra en la Figura 6.1.5; Oscilatorio en X, Oscilatorio en Y, o bien mediante un relleno en espiral.

En estos primeros esquemas de relleno oscilatorio nunca se produce la rotura de actividades, pues la línea de relleno siempre es continua y se van colocando las casillas de las actividades de manera continua.

Sin embargo, dependiendo de la forma y tamaño del recinto, del número de actividades y de la selección del tipo de oscilación que se seleccione, esta técnica puede dar lugar a formas de actividades excesivamente alargadas y no muy deseables (ocurre fundamentalmente con rellenos oscilatorios en X).

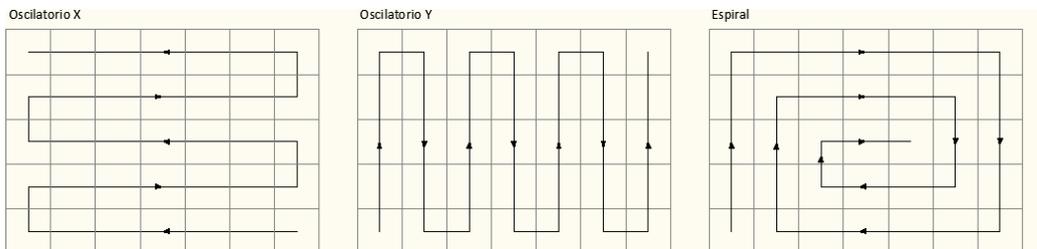


Figura 6.1.5 Relleno mediante distintas variantes de ALDEP.

Una cuarta opción que se presenta en (Seehof y Evans 1967) y que es la más empleada, consiste en realizar un relleno oscilatorio XY, alternando avance en ambas direcciones. Para ello se debe dividir el recinto en bandas, sobre las que ir realizando el relleno. En el artículo original, los autores dividían el recinto en bandas de igual anchura, tal y como se puede ver en la Figura 6.1.6, en la que se puede observar un ejemplo con tres bandas de ancho igual a 2.

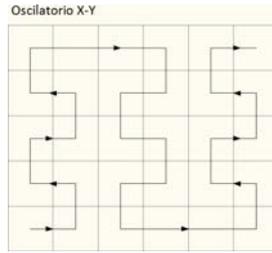


Figura 6.1.6 Relleno ALDEP oscilatorio XY (ancho de banda igual).

El relleno oscilatorio XY tipo ALDEP ha sido ampliamente empleado como técnica de construcción de soluciones por los autores que abordado el problema de distribución en planta, tanto en el caso de formulaciones mono como multiobjetivo, cuando el modelo geométrico es discreto.

Una evolución de la técnica ALDEP se puede encontrar en (Islier 1998), que aborda el problema de distribución en planta multiobjetivo sobre un modelo geométrico discreto y con una técnica de relleno oscilatorio tipo ALDEP con ancho de banda desigual (ver Figura 6.1.7). Esta misma técnica la emplean también otros autores como (Gonzalez 2005).

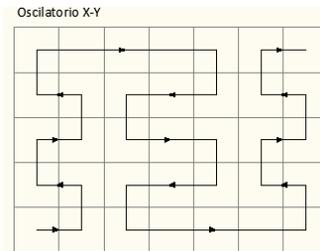


Figura 6.1.7 Relleno oscilatorio de bandas desiguales (Islier 1998).

Esta técnica de relleno funciona perfectamente, sin rotura siempre que el número de casillas de discretización en Y (a la que se llamará n_h) sea impar, en cuyo caso, el relleno debe comenzar en la casilla (1,1), tal y como se muestra en la Figura 6.1.8 .

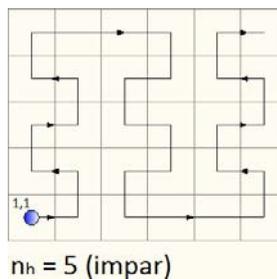


Figura 6.1.8 Problemas con ALDEP y el número de celdas n_h .

Si n_h es impar, esta técnica de relleno tiene más problemas, de partida hay que empezar el relleno en la celda (2,1) para evitar que se produzca la rotura cuando se alcanza la parte superior (ver Figura 6.1.9). Aun así se producirá rotura en algunos casos, como cuando el número de bandas sea mayor de 2, en la figura se puede ver el caso de rotura (en rojo), para el caso de 3 bandas y cómo no se produce rotura si el número de bandas es par.

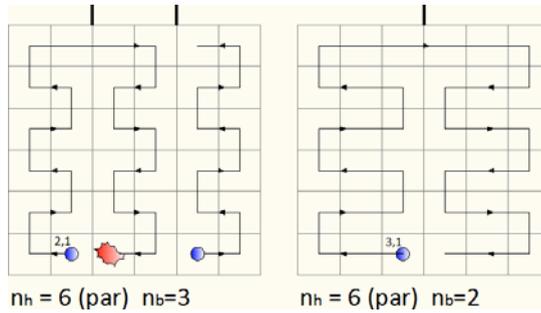


Figura 6.1.9 Problemas con ALDEP, el número de celdas n_h y el número de bandas n_b .

Por tanto, la rotura aparecerá en los casos que se muestran en la siguiente tabla, en cuyo caso habrá que disponer algún sistema para desechar las soluciones.

| | | Número de casillas en Y (n_h) | |
|-----------|-------|-----------------------------------|-----------|
| | | Par | Impar |
| Nº Bandas | Par | No Rotura | No Rotura |
| | Impar | Rotura | No Rotura |

Tabla 6.1.1 Casos que provocan rotura.

Esta rotura puede ocasionar la disgregación de alguna de las actividades, por tanto se ha de emplear una técnica de control de agregación, algunos autores como (Contero 1995) y (Gonzalez 2005) emplean técnicas de este tipo.

6.1.2.1.2 Curvas de relleno del Espacio - SFC

Una evolución a la técnica ALDEP es la construcción de soluciones mediante curvas de relleno del espacio, o SFC (*Space Filling Curves*). Esta técnica, ampliamente estudiada por los matemáticos, fue empleada por primera vez en un problema de optimización en (Bartholdi III y Platzman 1982), donde es aplicada para la resolución del problema TSP (problema del viajante de comercio).

La primera aplicación de esta técnica de relleno al problema de distribución en planta se puede encontrar en el algoritmo MULTIPLE, propuesto por (Bozer, Meller y Erlebacher 1994). En el mismo, los autores describen la SFC como "una línea continua que une todas las casillas de un recinto (discretizado) sin producir disgregación de la actividad, pues el tránsito de un punto siempre es hacia otra casilla vecina".

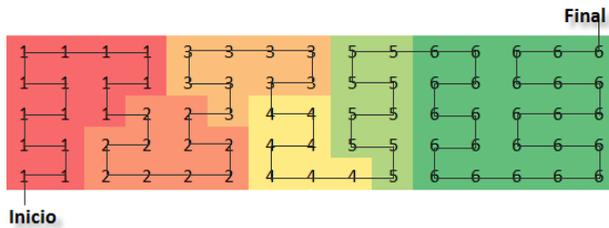


Figura 6.1.10 Ejemplo de SFC, adaptado de (Bozer, Meller y Erlebacher 1994).

En un edificio rectangular, sin actividades fijas o zonas vetadas, la SFC puede obtenerse mediante un método recursivo que da lugar a la denominada "curva de Hilbert", que fue propuesta por el autor homónimo en 1891. Una descripción de este método recursivo puede encontrarse en el apéndice del artículo de Bozer y Meller, para casos en los que el número de celdas horizontales (n_a) sea igual a 2^n .

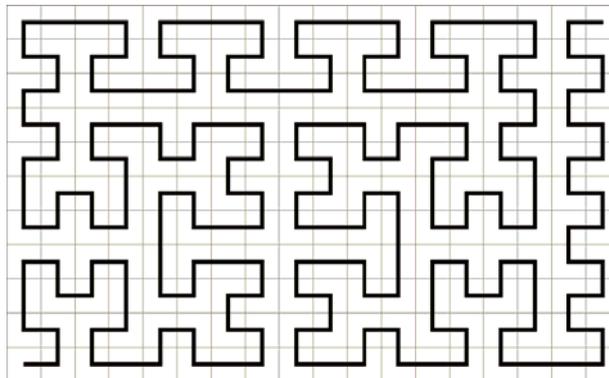


Figura 6.1.11 SFC generada mediante el método sugerido en (Bozer, Meller y Erlebacher 1994).

Si la forma del edificio no es rectangular o hay actividades inamovibles o espacios no accesibles, la curva puede fijarse manualmente (aunque la misma no sea matemáticamente una SFC, funcionalmente sí que lo será).

En (Wang, Hu y Ku 2005) se puede encontrar una evolución de estas curvas aplicadas al problema de distribución en planta, donde los autores formulan un procedimiento basado en reglas IF-THEN para conformar una SFC sobre un soporte discreto, y que funciona correctamente independientemente de si el número de casillas verticales y horizontales es par o impar y sin limitaciones de ningún tipo.

En este procedimiento se deben fijar los siguientes valores:

- Ancho del recinto (altura): W
- Largo del recinto (longitud): L
- Fila de la posición actual: I
- Columna actual: J
- Dirección de barrido: D
- Ancho de banda: B
- Paso del barrido: F

Con todos ellos, los autores establecen una serie de reglas IF-THEN que determinan el buen funcionamiento de la curva de relleno, evitando en cualquier caso la rotura de la misma y garantizando que se van a recorrer todas las casillas del recinto pasando por ellas una sola vez.

El proceso de generación de la SFC se muestra en el diagrama de la Figura 6.1.12, y las reglas de decisión marcan el criterio de movimiento hacia la nueva celda cuando se ha llegado al final de una de las bandas de relleno.

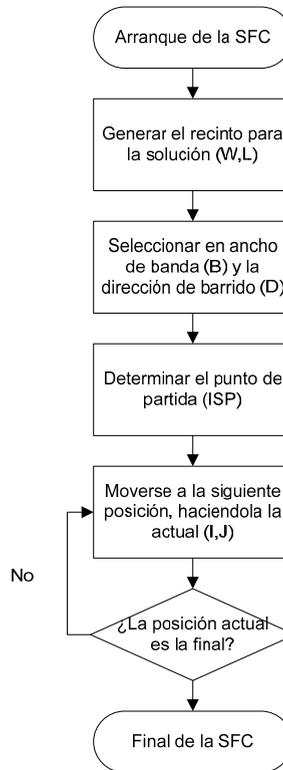


Figura 6.1.12 Procedimiento de Wang para SFC.

La codificación que se emplea para marcar la posición actual (CP) del constructor es la que se muestra en la ecuación (6.2), donde el significado de la mayor parte de las letras ha sido comentado con anterioridad. Los dos parámetros que no se han comentado son los siguientes:

- C: es un contador del número de bandas, que va desde 0 hasta B-1.
- F: es la frecuencia de colocación, marca cual es la dirección de barrido en función de la dirección de barrido (D). Si D es horizontal y F es par, el barrido es de derecha a izquierda, si es impar, el barrido es de izquierda a derecha. Si D es vertical y F es par, el barrido es de abajo hacia arriba y si es impar, el barrido es de arriba hacia abajo.

$${}^L_w CP^D_B(F, I, J, C) \quad (6.2)$$

Posteriormente se enuncian reglas IF-THEN para la definición de la transición cuando se llega al final de cada una de las bandas, con una formulación similar a la mostrada en la ecuación (6.3), que es la regla de descenso en una banda al llegar al final del recinto.

$$\begin{aligned} \text{Si } & {}^L_w CP^D_B(D \& F \& I \& J \& C) \\ \text{Entonces } & I=I+1, F=F+1 \text{ moviéndose hacia abajo a } {}^L_w NP^D_B(F+1, I+1, J, C): \quad (6.3) \\ & {}^L_w CP^D_B(F+1, I+1, J, C) = {}^L_w NP^D_B(F+1, I+1, J, C) \end{aligned}$$

Los autores dejan claro que las reglas deben definirse para cada problema y para cada situación, las mismas deben conseguir que no se produzca la rotura en el proceso de colocación y que la misma sea continua a lo largo de todo el recinto.

6.1.2.1.3 Definición de la técnica de colocación empleada. SFC y sus reglas

En el presente trabajo, se ha optado por emplear una SFC, para lo cual se deben definir claramente los parámetros comentados en los puntos anteriores, para que la colocación de actividades sea continua y no se produzca disgregación de casillas. Se emplean curvas de relleno para evitar tener que hacer un control de agregación (como se hace en (Contero 1995) o más recientemente en (Gonzalez 2005)) y aunque el nivel de esfuerzo en la fase de programación y definición de la curva sea mayor, los resultados obtenidos mediante esta técnica son notables y prácticamente todos los autores que tratan el problema de distribución en planta con un modelo geométrico continuo emplean esta técnica.

En este apartado se definirán las reglas de transición al final de cada banda, así como parámetros básicos en la construcción de la SFC como son el inicio de la misma y otros aspectos de interés. Todas las figuras y los ejemplos empleados se montan sobre un tamaño de recinto de 30x20 unidades de espacio y con una resolución de la discretización de 1x1. Las bandas sobre las que se desarrolla la SFC serán de ancho desigual y las limitaciones de las mismas en cuanto a su tamaño se discuten en los siguientes apartados, así como la orientación de las mismas, que en este caso serán verticales.

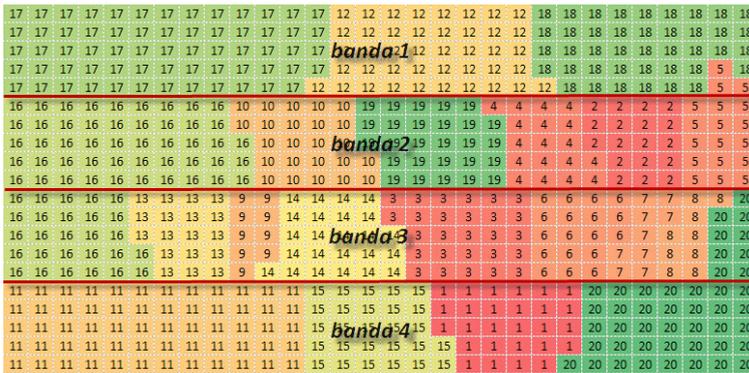


Figura 6.1.16 Solución 1 de (Wang, Hu y Ku 2005), con 4 bandas.

Tal y como se ha comentado en apartados anteriores, la metodología empleada en el presente trabajo utiliza una característica del algoritmo ALDEP (Seehof y Evans 1967), como es la utilización de bandas para colocación de las actividades en el recinto junto a la variabilidad del arranque de una SFC.

El uso de bandas para la colocación de actividades se puede encontrar en un gran número de referencias, tanto en modelos continuos (Tate y Smith 1995), (Islier 1998), (Meller y Gau 1996) como en modelos discretos (Wang, Hu y Ku 2005), (Gonzalez 2005).

En todas estas referencias, se pueden encontrar 3 variables básicas en lo relativo a las bandas empleadas en la estrategia de relleno del espacio, como son: el número de bandas, el ancho de cada una de las bandas y la secuencia de bandas empleadas.

Estas tres variables se emplearán posteriormente en el proceso de generación de nuevas soluciones, por ello se comentan a continuación con más detalle, pues son un elemento fundamental en el presente trabajo. En la Figura 6.1.17 se resumen todas las características que se deben tener en cuenta a la hora de generar las bandas de relleno y que se deben describir con detalle.



Figura 6.1.17 Variables en la estructura de bandas.

6.1.2.2.1 Número de bandas (n_b)

La primera de las variables que hay que fijar es el número de bandas que se van a establecer en el proceso de relleno del espacio. Esta variable se nombra con la abreviatura n_b y tendrá como cota inferior el valor unidad (en el caso de que se utilice una única banda, de ancho igual a la dimensión longitudinal del recinto) y como cota superior tantas bandas como casillas tenga el espacio de trabajo, en el caso de este trabajo, en el que las bandas se toman en sentido trasversal y ese parámetro viene dado por n_o , que es el número de casillas en sentido longitudinal ($n_o=30$, para el problema AB20).

En el proceso de generación de nuevas soluciones se pueden adoptar dos estrategias diferentes, en función de la variabilidad que se le quiera conferir al sistema de generación. Por una parte se puede mantener el número de bandas fijo o bien dejar una mayor libertad, posibilitando que el número de bandas sea variable en el proceso de generación de la vecindad de una solución.

Número de bandas fijo

En este tipo de estrategia se utiliza el mismo número de bandas n_b , en cada una de las etapas del proceso de generación de soluciones. La práctica totalidad de las referencias que emplean un espacio continuo (fundamentalmente mediante *flexbay*), utilizan en su mecanismo de generación de soluciones un número constante de bandas. En estos casos la anchura de cada una de las bandas puede ser variable o fija, independientemente de que el número sí que sea fijo. En la Figura 6.1.18 se puede observar un ejemplo de esta estrategia en dos iteraciones sucesivas de un proceso de optimización. Este tipo de estrategia se puede encontrar en (Islir 1998), (Seehof y Evans 1967) y (Wang, Hu y Ku 2005).

Número de bandas variable

En contraste con la anterior, se encuentra la línea de dejar abierta la posibilidad de que el número de bandas sea variable entre cada una de las iteraciones del proceso de optimización. En apartados posteriores se establecerán los mecanismos habilitados para generar la vecindad de una solución en términos de número de bandas, pues no es posible pasar de una estructura de bandas a otra cualquiera de las posibles, sino que hay que restringir ese camino a soluciones que sean cercanas a la actual. Este tipo de estrategia se puede encontrar en (Gonzalez 2005), (Meller y Gau 1996) y (Tate y Smith 1995).

En el presente trabajo se empleará una estrategia de número de bandas variable, para permitir una mayor diversidad en la búsqueda de soluciones, fijando el número mínimo de bandas en 1 (se correspondería con un relleno oscilatorio en X) y un número de bandas máximo de 15 (influenciado por el ancho de banda mínimo, aspecto que se comenta a continuación). Por tanto:

$$1 \leq n_b \leq 15 \quad (6.6)$$

6.1.2.2.2 *Ancho de Banda (b_i)*

La segunda de las variables a fijar es el ancho de cada una de las bandas empleadas en el proceso de construcción de las soluciones. Esta variable fija dos características relativas al ancho de banda, por una parte se puede fijar el tamaño del ancho de banda, estableciendo un mínimo y un máximo para este valor. En la bibliografía se encuentran las siguientes referencias a estas características:

En (Islir 1998) se puede encontrar una limitación en lo relativo al ancho de banda mínimo y máximo para obtener soluciones formalmente eficientes, el intervalo queda fijado mediante la siguiente expresión:

$$\min_{i=1}^n(A_i) \leq b_i \leq \sqrt{\max_{i=1}^n(A_i)} \quad (6.7)$$

Donde: A_i es el área de la actividad i -ésima.

b_i es el ancho de banda.

En (Gonzalez 2005) se propone la utilización de un rango de valores para la anchura de las bandas que queda limitado por la siguiente expresión:

$$1 + \sqrt{\min_{i=1}^n(A_i)} \leq b_i \leq 1 + \sqrt{\max_{i=1}^n(A_i)} \quad (6.8)$$

Esta limitación en la anchura de cada una de las bandas condiciona también el número de bandas mínimo y máximo comentado anteriormente y que queda limitado por estos dos valores.

En el presente trabajo se opta por establecer un valor máximo para el ancho de banda igual a la anchura total del recinto, y fijando un valor mínimo del mismo de 2, para evitar formas excesivamente alargadas de las actividades. Por tanto, el ancho de banda queda limitado por:

$$2 \leq b_i \leq 28 \quad (6.9)$$

Una vez fijado las características relativas al tamaño del ancho de banda, resta por describir los aspectos relativos a la secuencia de los anchos de banda de cada una de las mismas. En este caso se puede fijarse un ancho igual para cada una de las bandas empleadas o bien permitir que el ancho sea variable.

Ancho de banda fijo

En esta estrategia de construcción de soluciones, se fija un valor constante para el ancho de cada una de las bandas ($b_i = b_j, \forall i, j$).

$$b_i = cte \quad / \quad \sum_{i=1}^{nb} b_i = n_a = nb \cdot b_i \quad (6.10)$$

Donde n_a es el número de celdas en la dirección a del recinto.

b_i es el ancho de la banda i-ésima.

nb es el número de bandas.

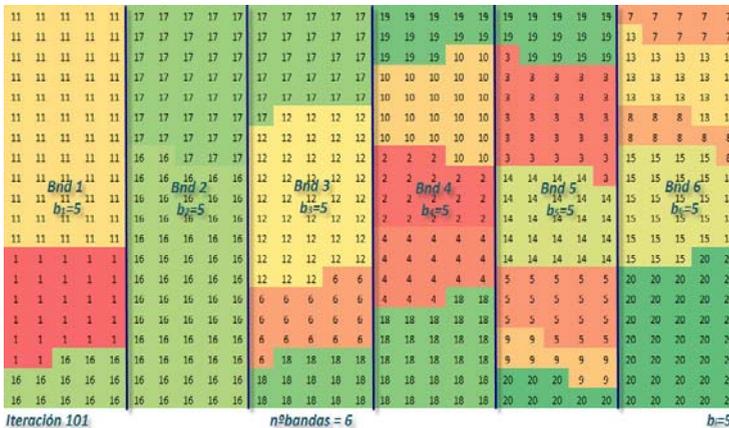
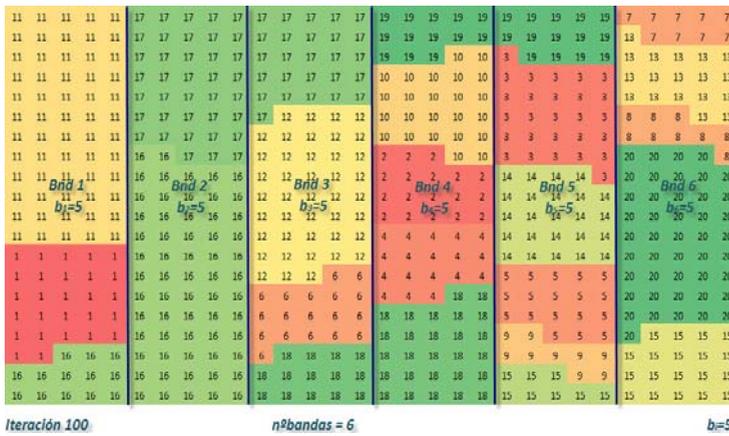


Figura 6.1.18 Dos iteraciones sucesivas en una estrategia con $nb_i=cte$ y $b_i=cte$.

Ancho de banda variable

Por otra parte se puede utilizar una estrategia consistente en emplear anchos de banda diferentes para cada una de las bandas en las que se subdivide el espacio sobre el que actúa el mecanismo de colocación de actividades. En cualquier caso, se debe verificar que:

$$\exists i, j / b_i \neq b_j / \sum_{i=1}^{nb} b_i = n_o \tag{6.11}$$

- Donde: n_o es el número de columnas del recinto.
- b_i es el ancho de la banda i-ésima.
- nb es el número de bandas.

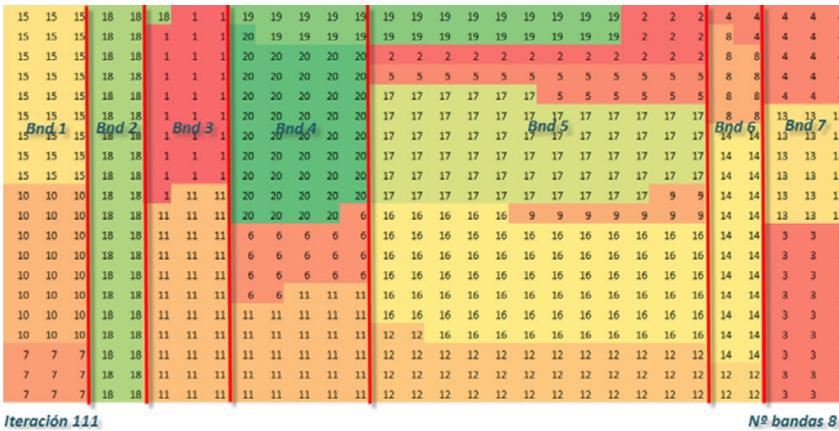


Figura 6.1.19 Solución con un ancho de banda variable $b_i \neq cte$.

6.1.2.2.3 Secuencia de bandas

Por último, la tercera de las variables relativas a las bandas de colocación de actividades queda determinada por la capacidad de variar el ancho y el número de bandas entre distintas iteraciones del proceso de optimización.

Esta variable en realidad es una combinación de las dos anteriores, tal y como se muestra en la Tabla 6.1.2, en la que se resumen las diferentes opciones a la hora de realizar la generación de una solución, en lo relativo a las bandas empleadas en el proceso de construcción de la misma.

| | | Número de Bandas | |
|----------------|----------|----------------------|----------------------|
| | | Fijo | Variable |
| Ancho de Banda | Fijo | <i>ESTÁTICA</i> | <i>Semi-DINÁMICA</i> |
| | Variable | <i>Semi-DINÁMICA</i> | <i>DINÁMICA</i> |

Tabla 6.1.2 Definición de variables de bandas - Secuencia de Bandas.

Secuencia de bandas estática

En esta estrategia, tanto el número como el ancho de banda son constantes entre dos iteraciones del proceso de optimización, tal y como se puede observar en la Figura 6.1.18.

Secuencia de bandas semi-dinámica

En esta estrategia se permite, entre dos iteraciones del proceso, que se varíen bien el ancho o el número de bandas de generación de soluciones.

Secuencia de bandas dinámica

En el caso de emplear una secuencia de bandas dinámica, la configuración de bandas (en tamaño y número) puede modificarse entre diferentes iteraciones del proceso de optimización, tal y como ocurre en la Figura 6.1.20.

En el presente trabajo se opta por emplear una **secuencia de bandas dinámica**, pues proporciona una mayor capacidad de búsqueda en el espacio de soluciones, permitiendo alcanzar desde un punto, configuraciones que de otra forma serían inalcanzables, a costa de un tiempo mayor de proceso.

6.1.3 Codificación de las soluciones

Con la definición de todas las variables comentadas en este punto, solo resta establecer una codificación que defina, de manera biunívoca, cada una de las soluciones que se pueden obtener con el modelo geométrico empleado en la presente investigación. Para ello se propone emplear la siguiente codificación:

$$3-6-9-8-2-1-4-7-5-10 \left| \begin{array}{c} 2 \\ \text{n}^\circ \text{ bandas} \end{array} \right| \left| \begin{array}{c} 3-5 \\ \text{secuencia bandas} \end{array} \right| \left| \begin{array}{c} 1.5 \\ \text{recinto} \end{array} \right| \quad (6.12)$$

Con la codificación expresada en la ecuación (6.12) se recogen los aspectos de la secuencia de colocación de las actividades, el número de bandas y los anchos de cada una de las bandas y por último las características de orientación y por ende las de la direccionalidad de las bandas.

Todos los aspectos recogidos en este código han sido comentados en este mismo capítulo y definen de forma biunívoca cada una de las soluciones obtenidas. Como ejemplo se puede observar en la siguiente figura.

$$1-18-11-16-17-13-15-10-12-5-14-9-3-8-19-2-4-7-20-6 \left| 7 \right| \left| 2+2+2+2+2+18 \right| 1.5 \left| (6.13) \right.$$

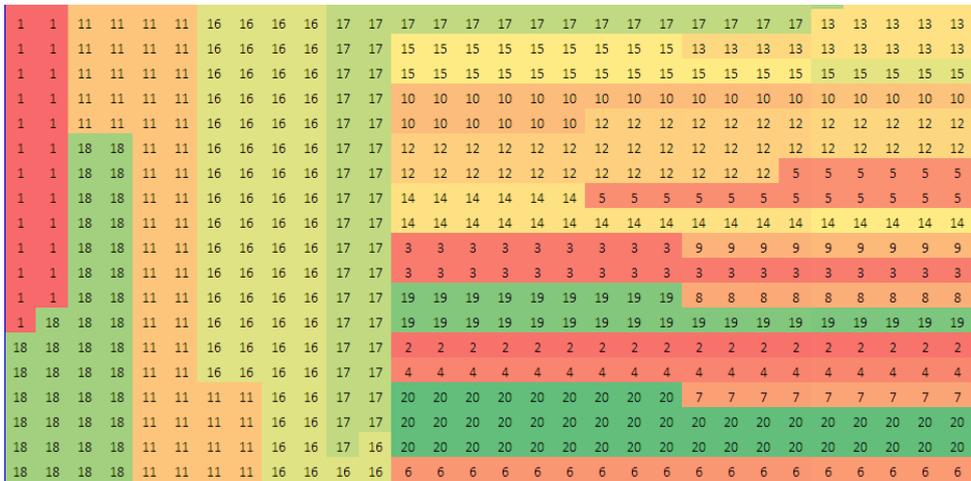


Figura 6.1.21 Solución 1 de la frontera Coste-Circulación, con un valor nulo de circulación.

En el capítulo de resultados se empleará esta codificación, eliminando el último de los términos, que es común en todos los experimentos y adquiere siempre el valor de 1.5.

6.2 GENERACIÓN DE SOLUCIONES

Una vez conocidas las diferentes variables que influyen en el proceso de construcción de nuevas soluciones resta por definir la mecánica que se va a emplear para generar nuevas soluciones.

Para garantizar la diversidad en el espacio de soluciones explorado, y evitar el estancamiento en óptimos locales, se emplea una característica fundamental de una metaheurística de entorno variable como es el VNS (*Variable Neighborhood Search*), propuesto en (Mladenovic y Hansen 1997), como es la variación sistemática de la estructura de la vecindad de la solución.

En este apartado se definirá como está compuesta la vecindad de una solución y los mecanismos que se emplearán para garantizar la diversidad del proceso de optimización.

6.2.1 Espacio de soluciones - Vecindad de una solución

Para realizar la transición a una nueva solución se emplea el concepto de *vecindad de una solución*, entendiéndose como tal a aquel conjunto de soluciones que son accesibles desde la solución actual, mediante el intercambio de una (y solo una) de las variables de construcción de la misma.

En la Figura 6.2.1 se muestra una solución (en color azul) y todas las soluciones accesibles desde ella (soluciones de la vecindad, en morado). El tamaño de la vecindad, así como su composición y reglas de transición varían en función de las variables de la solución actual y de la metaheurística empleada para definir la transición.

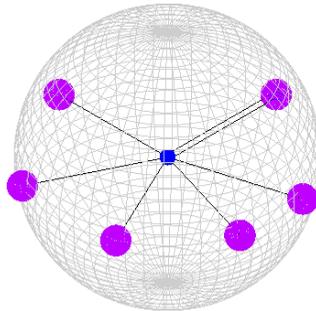


Figura 6.2.1 Vecindad de una solución.

Por tanto, la transición de una solución se realizará siempre a soluciones que pertenezcan a la vecindad de la misma y así sucesivamente. En la Figura 6.2.2 se muestra el proceso de transición de una solución actual a otra de su vecindad (izq), la generación de la vecindad de esa nueva solución y la transición a una de las soluciones vecinas (cen) y la continuación de este procedimiento (der).

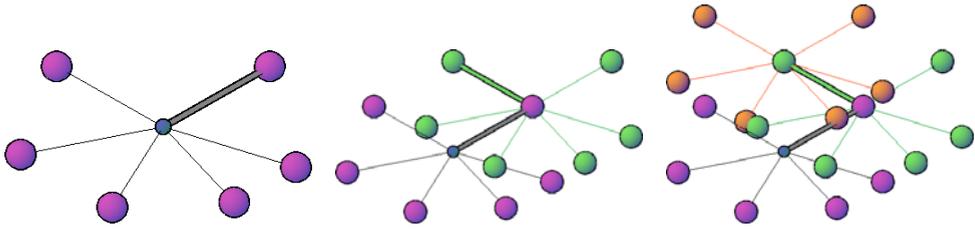


Figura 6.2.2 Búsqueda por entornos variables. Transición a solución vecina.

El tamaño de la vecindad de una solución varía en función de los valores que definen la solución actual (numero y tamaño de bandas, secuencia de colocación...) cuestiones que se abordan en los siguientes puntos.

6.2.2 Mecanismos de generación

En el presente trabajo se consideran cuatro mecanismos de generación de nuevas soluciones desde una determinada configuración del problema, basadas todas ellas en variaciones de los dos elementos fundamentales empleados en la construcción de soluciones, por una parte en la secuencia de entrada de las actividades y por otra en la estructura de bandas que se emplee durante el relleno del espacio.

Tal y como se ha comentado con anterioridad, desde una solución dada no se puede acceder a cualquier otra del espacio de soluciones, dado que entonces la búsqueda no es guiada, sino que se convierte en una búsqueda aleatoria.

El tamaño de la vecindad se verá que varía para las diferentes soluciones que se pueden encontrar en el espacio de soluciones, en función del número de bandas que tenga la configuración de origen.

6.2.2.1 Intercambio de actividades

El primer mecanismo es el basado en el intercambio de posición de dos actividades dentro del vector que marca la secuencia de colocación de las mismas sobre el recinto. Se considera que dos secuencias de actividades son vecinas si una se puede obtener por el intercambio de posición de un par de elementos del vector. La selección de las dos actividades cuya posición va a ser intercambiada se realiza de forma aleatoria.

Los vectores de entrada de actividades \vec{a}_k y \vec{a}_{k+1} mostrados en la (6.14) son vecinos, pues \vec{a}_{k+1} se obtiene por el intercambio de las actividades i y j del vector \vec{a}_k . Por tanto se puede decir que la configuración obtenida mediante el vector \vec{a}_{k+1} está en la vecindad de la configuración obtenida mediante el vector \vec{a}_k .

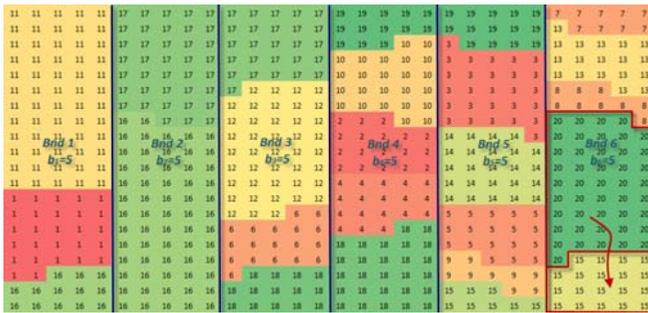
$$\vec{a}_k = [a_1, a_2, a_3, \dots, a_i, a_{i+1}, \dots, a_j, a_{j+1}, \dots, a_n]$$

$$\vec{a}_{k+1} = [a_1, a_2, a_3, \dots, a_i, a_{i+1}, \dots, a_j, a_{j+1}, \dots, a_n]$$
(6.14)

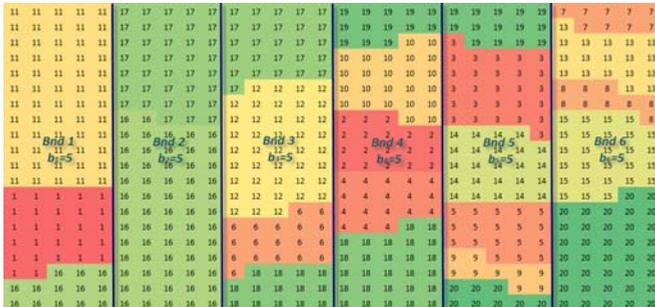
El intercambio de actividades (*swapping*) es una técnica de obtención de nuevas soluciones ampliamente empleada en la bibliografía, y da lugar a un tamaño de la vecindad (*Vec*) que es función del número de actividades (*n*) del que se componga el problema en cuestión. La vecindad en este caso sería el calculado en (6.15), que para el caso de un problema como el AB20 será igual a 190.

$$Vec_{MA}(n) = \frac{n(n-1)}{2}$$
(6.15)

En la Figura 6.2.3 se pueden observar una solución \vec{a}_{k+1} en la vecindad de la solución \vec{a}_k , obtenida por el intercambio de la posición de entrada de las actividades 20 y 15.



$\vec{a}_k = 11 - 1 - 16 - 17 - 12 - 6 - 18 - 4 - 2 - 10 - 19 - 3 - 14 - 5 - 9 - \underline{15-20} - 8 - 13 - 7$



$\vec{a}_{k+1} = 11 - 1 - 16 - 17 - 12 - 6 - 18 - 4 - 2 - 10 - 19 - 3 - 14 - 5 - 9 - \underline{20-15} - 8 - 13 - 7$
swap

Figura 6.2.3 Solución \vec{a}_{k+1} en la vecindad de la configuración \vec{a}_k .

6.2.2.2 Intercambio de bandas

El segundo de los elementos a variar para obtener soluciones vecinas a una determinada configuración es realizar la modificación de la estructura de bandas empleada en la construcción de soluciones, recogida en el vector de bandas $\vec{b} = [b_1, b_2, \dots, b_i, \dots, b_j, \dots, b_{nb}]$, debiéndose cumplir siempre que:

$$\sum_{i=1}^{nb} b_i = n_a \quad (6.16)$$

Donde: nb es el número de bandas empleadas en el proceso de construcción y n_a es el número de celdas en la dirección a , que es la perpendicular a las bandas, tal y como se comentó con anterioridad.

El primer mecanismo empleado en lo relativo a la estructura de bandas es el intercambio de dos de los elementos del vector de bandas \vec{b} . Este mecanismo de generación dará lugar a soluciones diferentes siempre que en ancho de las dos bandas a intercambiar sea diferente. El tamaño de la vecindad atendiendo a este mecanismo de generación es función del número de bandas de la configuración de origen:

$$\text{Vec}_{MB1}(nb) = \frac{nb \cdot (nb - 1)}{2} \quad (6.17)$$

Para el caso de una solución como las mostradas en la Figura 6.2.3, con 6 bandas, el tamaño de la vecindad para el intercambio de bandas sería $\text{Vec}_{MB1}(6) = 15$ (remarcar que en este caso sería nulo pues todas las bandas tienen idéntico ancho $b_1 = b_2 = \dots = b_6 = 5$).

La cota superior del tamaño de la vecindad en este caso está marcado por el número de bandas máximo que pueda existir según sea la discretización y tamaño del recinto.

Para el caso en estudio, del problema de (Armour y Buffa 1963) de 20 actividades, con un recinto de 30x20 y con un tamaño de discretización igual a la unidad (30x20 unidades), si el ancho de banda mínimo es de 2 casillas, el número máximo de bandas será de 15 (tal y como se comentó en apartados anteriores), por tanto el tamaño máximo de la vecindad será de:

$$\text{Vec}_{MB1}(15) = \frac{15 \cdot (15 - 1)}{2} = 105 \quad (6.18)$$

6.2.2.3 Agregación de bandas

Para mejorar el aspecto resaltado en el mecanismo del intercambio de bandas en lo relativo al estancamiento debido a la igualdad en el ancho de banda se introduce un nuevo mecanismo de generación basado en la modificación del tamaño y del ancho de las bandas, basado en la agregación de dos de las bandas del vector \vec{b}_k .

Como condición general se impone que únicamente se pueden agregar dos (y solamente dos) bandas que sean contiguas, debiéndose cumplir siempre lo expresado en la ecuación (6.16). Por tanto la solución de la vecindad siempre va a tener una banda menos que la solución de origen, y el número máximo de soluciones de la vecindad atendiendo a este mecanismo de generación será función del número de bandas, y en este caso:

$$\text{Vec}_{\text{MB2}}(nb) = (nb - 1) \quad (6.19)$$

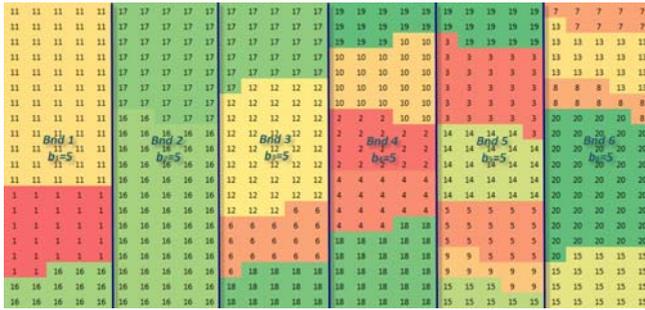
Para el caso de una solución como las mostradas en la Figura 6.2.3, con 6 bandas, el tamaño de la vecindad para la agregación de bandas sería $\text{Vec}_{\text{MB2}}(6) = 5$ (remarcar que en este caso sería igual a 1, pues todas las bandas tienen idéntico ancho $b_1 = b_2 = \dots = b_6 = 5$).

La cota superior del tamaño de la vecindad en este caso está marcado por el número de bandas máximo que pueda existir según sea la discretización y tamaño del recinto.

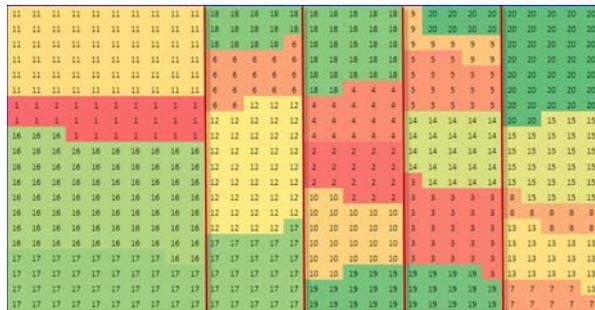
Para el caso en estudio, del problema de (Armour y Buffa 1963) de 20 actividades, tal y como se comentó con anterioridad, la cota superior del número de bandas sería 15, siendo en este caso el tamaño de la vecindad máximo igual a:

$$\text{Vec}_{\text{MB2}}(15) = (15 - 1) = 14 \quad (6.20)$$

En la siguiente figura se pueden observar dos soluciones vecinas, partiendo de la misma solución que en la Figura 6.2.3, agregando dos bandas, en este caso las dos primeras y manteniendo la secuencia de entrada de las actividades.



$$\vec{b}_k = \underline{5-5-5-5-5}$$



$$\vec{b}_{k+1} = \underline{10-5-5-5-5}$$

Figura 6.2.4 Solución \vec{b}_{k+1} en la vecindad de la configuración \vec{b}_k .

6.2.2.4 Expansión de bandas

El tercer mecanismo de generación de soluciones basado en la modificación del vector de bandas es el denominado mecanismo de expansión de bandas. El objetivo de este mecanismo, al igual que el anterior es conseguir desbloquear situaciones en las que el intercambio de bandas se haya estancado por la igualdad del ancho de banda.

El mecanismo se fundamenta en expandir una de las bandas, desglosándola en dos, cuya suma tenga un ancho de banda igual al ancho de la banda de partida. El procedimiento de generación basado en la expansión de bandas es el siguiente; se selecciona una de las bandas del vector y se hace una división aleatoria en dos bandas que tengan un ancho superior al ancho mínimo de banda (fijado en 2), siguiendo estas premisas el tamaño de la vecindad atendiendo únicamente a este mecanismo será:

$$\text{Vec}_{\text{MB3}}(nb) = nb \tag{6.21}$$

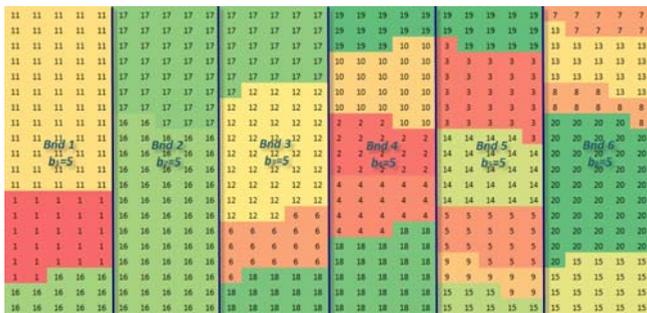
Para el caso de una solución como las mostradas en la Figura 6.2.3, con 6 bandas, el tamaño de la vecindad para la agregación de bandas sería $\text{Vec}_{\text{MB2}}(6)=6$, en realidad la

vecindad podría ser mayor, puesto que una banda lo suficientemente ancha (mayor de 6 unidades) puede dividirse de diferentes formas, cumpliendo el requisito de anchura, aunque es difícil de evaluar.

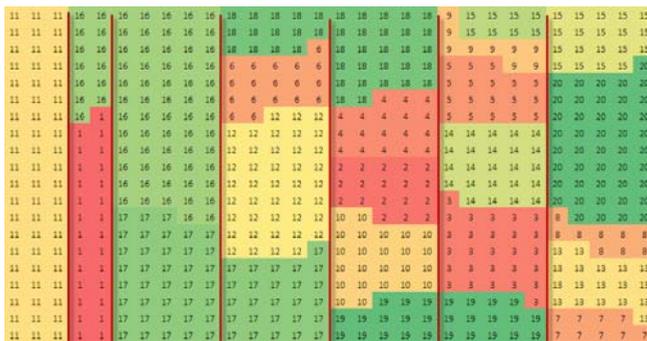
La cota superior del tamaño de la vecindad en este caso está marcado por el número de bandas máximo que pueda existir según sea la discretización y tamaño del recinto, siempre que el ancho de la banda sea mayor de 4, pues cualquier anchura inferior a este valor daría lugar a configuraciones no admisibles (de anchura de banda menor a 2).

Para el caso en estudio, del problema de (Armour y Buffa 1963) de 20 actividades, tal y como se comentó con anterioridad, la cota superior del número de bandas sería 15, siendo en este caso el tamaño de la vecindad máximo igual a:

$$\text{Vec}_{MB3}(15) = 15 \tag{6.22}$$



$$\bar{b}_k = \underline{5} - 5 - 5 - 5 - 5$$



$$\bar{b}_{k+1} = \underline{3+2} - 5 - 5 - 5 - 5$$

Figura 6.2.5 Solución \bar{b}_{k+1} en la vecindad de la configuración \bar{b}_k .

En la Figura 6.2.5 se pueden observar dos soluciones vecinas, partiendo de la misma solución que en la Figura 6.2.3, agregando dos bandas, en este caso las dos primeras y manteniendo la secuencia de entrada de las actividades.

6.2.3 Tamaño de la vecindad

Con estos mecanismos de generación de soluciones se puede considerar el cálculo del tamaño de la vecindad de una determinada configuración de un problema de m actividades con n bandas, mediante la siguiente expresión:

$$\begin{aligned} \text{Vec}(n,b) &= \text{Vec}_{MA}(n) + \text{Vec}_{MB1}(nb) + \text{Vec}_{MB2}(nb) + \text{Vec}_{MB3}(nb) \\ \text{Vec}(n,b) &= \frac{n \cdot (n-1)}{2} + (nb-1) + (nb-1) + nb = \frac{n \cdot (n-1)}{2} + (3nb-2) \end{aligned} \quad (6.23)$$

Por tanto, el tamaño de la vecindad es función del número de actividades del problema y del número de bandas, por tanto, para el problema empleado en el presente trabajo, el de Armour y Buffa de 20 actividades, varía con los límites mostrados en la Figura 6.2.6.

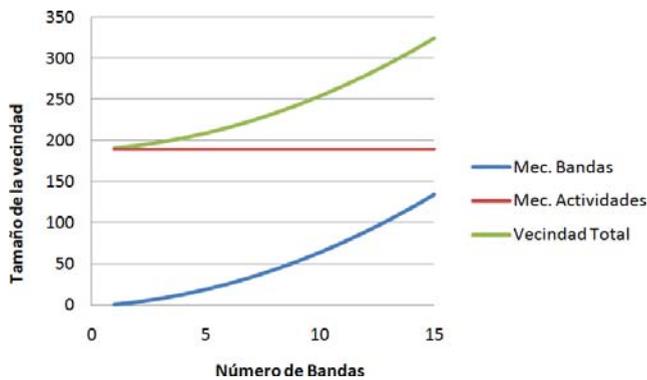


Figura 6.2.6 Variación del tamaño de la vecindad para el problema AB20.

La evolución del número de soluciones que conforman la vecindad con las bandas de la configuración de partida es la que se muestra en la Figura 6.2.7.

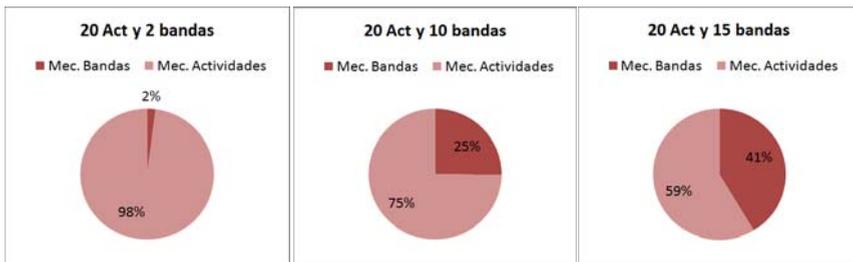


Figura 6.2.7 Porcentajes de tamaño de vecindad según diferentes mecanismos de generación.

Para el caso en el que el tamaño de vecindad es el mayor posible, la distribución del tamaño de la vecindad para el problema AB20 y con un modelo geométrico discreto es el mostrado en la Figura 6.2.8.

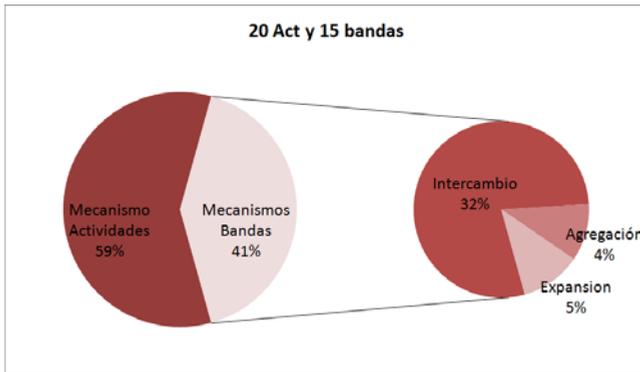


Figura 6.2.8 Porcentajes de tamaño de vecindad según diferentes mecanismos de generación.

La siguiente decisión a tomar es qué mecanismo de generación emplear en cada momento del proceso de optimización. Para garantizar una mayor diversidad del mismo, se opta por obligar a emplear los cuatro mecanismos, aunque queda por determinar en qué momento se emplea cada uno de ellos.

La utilización de uno u otro mecanismo se decidirá mediante una selección aleatoria, dotando a cada uno de los cuatro mecanismos un mayor porcentaje de probabilidad de ocurrencia, tal y como si fuera un juego de la ruleta. Se selecciona un número aleatorio en el rango $[0,1]$, que hace las veces de bola de la ruleta, y esta ruleta está formada por los diferentes mecanismos de generación, distribuidos de forma uniforme en el rango $[0,1]$.

¿En qué medida se emplea cada uno de los cuatro mecanismos? Para resolver este problema, partiendo de la base de que se obliga a que los cuatro mecanismos entren en juego para garantizar la diversidad del proceso, se realiza un experimento basado en DLS (*Descent Local Search*).

Este experimento se monta sobre el modelo geométrico discreto para el problema de Armour y Buffa de 10 actividades sobre soporte discreto y empleando una curva de colocación de actividades como la comentada anteriormente. En cada experimento se lanzan 50 pruebas y se configura la ruleta de transición a una nueva solución de la vecindad con diferentes porcentajes para cada uno de los mecanismos de generación de soluciones (orientando de esta forma la transición hacia soluciones de una vecindad de uno u otro mecanismo). La solución se acepta si y solo si produce un descenso en la función de coste, buscando otra solución vecina en caso contrario.

En la Tabla 6.2.1 se observan los experimentos realizados para diferentes composiciones de la “ruleta de transición”, quedando claro que entre estas opciones la mejor estrategia de composición es la que emplea una distribución de la misma proporcional al tamaño la vecindad de cada uno de los mecanismos de generación de soluciones comentados con anterioridad.

| Intercambio Actividades | Intercambio de bandas | | | Mínimo Coste | Coste Medio |
|-------------------------|-----------------------|-----|-----|--------------|-------------|
| | MA | MB1 | MB2 | | |
| Proporcional | | | | 5480,48 | 6962 |
| 70 | 10 | 10 | 10 | 5847,67 | 7045,52 |
| 30 | 30 | 30 | 10 | 6025 | 7619,56 |
| 30 | 30 | 10 | 30 | 6349,6 | 8196,4 |
| 30 | 10 | 30 | 30 | 6238,88 | 8038,9 |
| 25 | 25 | 25 | 25 | 6682,65 | 8160,9 |
| 10 | 70 | 10 | 10 | 6334,79 | 8601,68 |
| 10 | 10 | 70 | 10 | 6338,15 | 9070,79 |
| 10 | 10 | 10 | 70 | 7326,53 | 9343,4 |
| 10 | 30 | 30 | 30 | 6599,98 | 9092,54 |

Tabla 6.2.1 Experimento con DLS para obtener el porcentaje de los mecanismos de generación.

En la Figura 6.2.9 se pueden observar la posición de las soluciones de las 50 iteraciones del DLS realizado para la ruleta de transición proporcional finalmente seleccionada para aplicar en el procedimiento de optimización del presente trabajo.

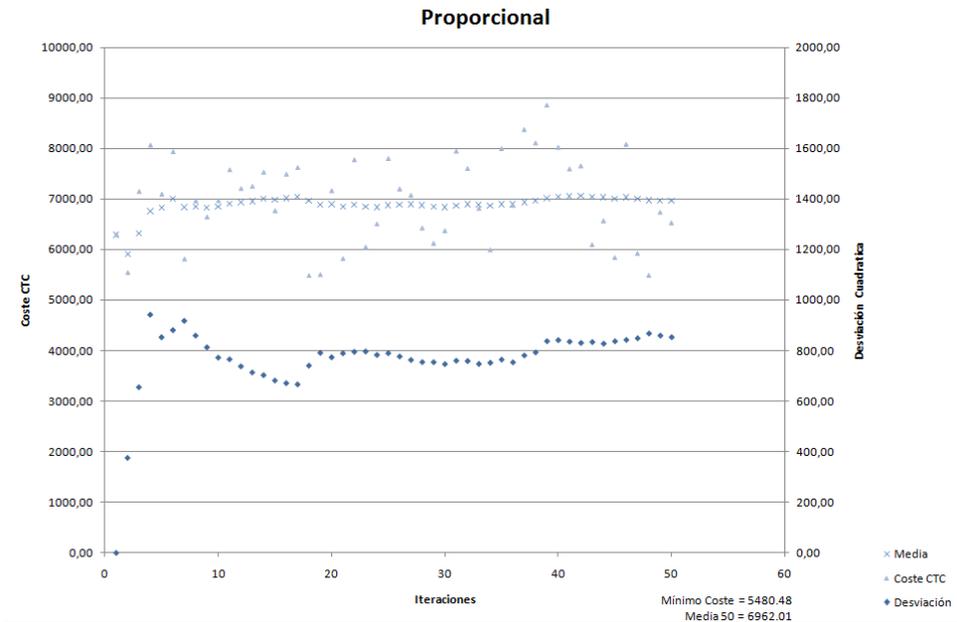


Figura 6.2.9 DLS para una “ruleta de transición” con distribución proporcional.

6.3 ALGORITMO DE OPTIMIZACIÓN EMPLEADO

6.3.1 Formulación del problema

Tal y como se comentó en el capítulo 3, se empleará una formulación cuantitativa del problema de distribución en planta. Este tipo de formulaciones se comenzaron a utilizar en (Koopmans y Beckman 1957) para un problema QAP y posteriormente fueron adaptadas al problema de distribución en planta para actividades multicasilla y empleadas en (Contero 1995) y (Gonzalez 2005).

Para facilitar la formulación de la función de coste, se emplea el concepto de variable de asignación x_{ik} , que adopta los siguientes valores:

$$x_{ik} = \begin{cases} 1 & \text{si la actividad } i \text{ ocupa la casilla } k\text{-ésima.} \\ 0 & \text{si la actividad } i \text{ no ocupa la casilla } k\text{-ésima.} \end{cases} \quad (6.24)$$

Las variables de asignación permiten establecer las distancias existentes entre dos actividades (i y j) de la configuración, mediante la siguiente expresión:

$$d_{ij} = \frac{1}{C_i \cdot C_j} \cdot \sum_{k=1}^c \sum_{l=1}^c d_{kl} \cdot x_{jl} \cdot x_{ik} \quad (6.25)$$

Considerando el dominio discreto y la función de coste expresada en términos de variables de asignación, la formulación del problema de distribución en planta con actividades de área variable que se va a utilizar es la siguiente:

$$\text{Min } C = \sum_{i=1}^n \sum_{j=1}^n \sum_{k=1}^c \sum_{l=1}^c \frac{W_{ij}}{C_i \cdot C_j} \cdot d_{kl} \cdot x_{ik} \cdot x_{jl} \quad (6.26)$$

s.t.

$$\sum_{k=1}^c x_{ik} = A_i \quad (6.27)$$

$$\sum_{i=1}^n x_{ik} = 1 \quad (6.28)$$

$$x_{ik} = x_{ik}^2 \quad (6.29)$$

La restricción (6.26) controla que cada actividad i este compuesta por un número de casillas tal que se alcance el área necesaria para la instalación (A_i). La restricción (6.28) vela por la no superposición de actividades en una misma casilla, por último, (6.29) no es una restricción como tal, sino que es la propia definición de la variable de asignación.

No se requiere una restricción de control de agregación, puesto que el mecanismo de colocación de actividades mediante SFC controla la desagregación de manera implícita.

Esta formulación se emplea para evaluar el indicador de coste de la solución, que es el principal de los objetivos del problema aunque no el único que se considerará, pues en función de los criterios que se designen en cada experimento se deberán evaluar empleando las correspondientes rutinas de cálculo.

6.3.2 Estructura de un algoritmo Simulated Annealing monobjetivo

Todo algoritmo que emplea una técnica de recocido simulado, o *Simulated Annealing* (en adelante SA) queda caracterizado mediante una serie de parámetros, que pueden ser clasificados en dos grandes grupos, por una parte los específicos del problema que se esté optimizando y otros genéricos, y que son independientes de la naturaleza del problema.

Los *parámetros específicos* del problema a optimizar, que han sido introducidos en los apartados precedentes de este capítulo, resumidos en:

- El **espacio de soluciones S** , que es el conjunto finito de todas las soluciones del problema que se va a optimizar.
- Una **función de coste f** definida como: $f : S \rightarrow \mathbb{R}$
- Un **mecanismo de generación**, de nuevas soluciones que permita obtener una solución del vecindario para evaluar su transición en el proceso de optimización.

Y por otra parte, habrá que definir una serie de *parámetros genéricos*, que constituyen lo que se denomina “*esquema de enfriamiento*” del algoritmo SA y que se deben fijar en el proceso de diseño del algoritmo:

- Una temperatura inicial T_0 .
- La ley de evolución de la temperatura.
- El criterio de equilibrio.
- El criterio de congelación

Este conjunto de parámetros es independiente del tipo de problema que se esté resolviendo, y controla el funcionamiento del algoritmo.

Como se indica en el diagrama de bloques de la Figura 6.3.1, el algoritmo realiza una serie de iteraciones a partir de la temperatura inicial (T_0), que posteriormente se fijará. En cada escalón de temperatura, se realizan una serie de iteraciones hasta que se verifica el criterio de equilibrio, condición que provoca una evolución en la temperatura del algoritmo mediante la ley de enfriamiento que se haya elegido.

El sistema va pasando por una serie de escalones de temperatura hasta que finalmente se verifica el criterio de congelación que marca la parada en el proceso de optimización.

Una característica fundamental del algoritmo SA es que, en la fase inicial del enfriamiento, cuando la temperatura es elevada, se produce un elevado número de transiciones que provocan un incremento de coste. A medida que el proceso de enfriamiento avanza, el sistema va gradualmente evolucionando hacia estados de menor coste.



Figura 6.3.1 SA monobjetivo.

En la Figura 6.3.2 se presenta un diagrama de flujo detallado de un algoritmo SA estándar, incluyendo un contador m de los escalones de temperatura realizados, ya que en muchas implementaciones del algoritmo se emplea para determinar la condición de congelación o calcular el siguiente escalón de temperatura según la ley de enfriamiento.

Se selecciona una solución de la vecindad de la configuración activa, evaluando la transición a ésta. Se produce de manera automática si disminuye coste y si produce un aumento se acepta con una probabilidad que es función de la temperatura actual (T_m).

Una vez aceptada la solución, se valora si se ha producido el equilibrio para el escalón de temperatura actual (T_m), en cuyo caso se disminuye la misma siguiendo la ley de enfriamiento, sino se vuelve a evaluar a una nueva solución de la vecindad.

Si se ha producido el equilibrio para el escalón de temperatura, se comprueba si el algoritmo ha alcanzado la temperatura mínima, produciéndose en tal caso la congelación del mismo.

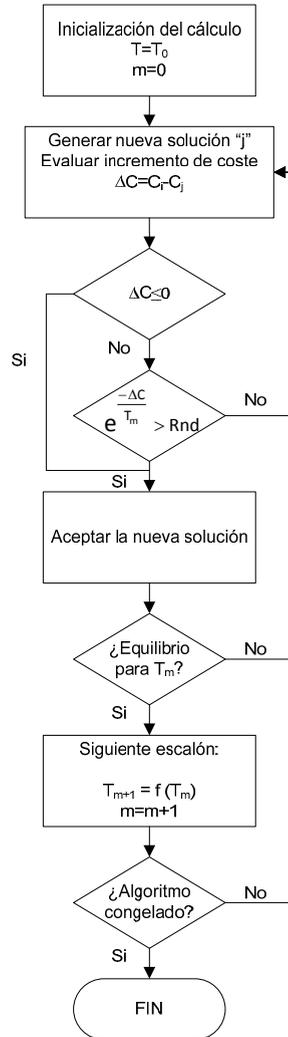


Figura 6.3.2 SA monobjetivo detallado.

6.3.2.1 Modelo matemático del algoritmo.

Se puede considerar que una vez establecido el espacio de soluciones, el mecanismo de generación y la estructura de la vecindad a una solución dada, el funcionamiento de un algoritmo SA consiste en un intento continuo de transformación de la configuración actual en alguna de sus configuraciones vecinas.

Este mecanismo es matemáticamente asimilable a una *cadena de Markov*, es decir corresponde a una secuencia de experimentos, en la que el resultado de cada experimento depende únicamente del resultado del experimento anterior. En el caso de un algoritmo SA, los experimentos equivalen a las transiciones, y es evidente que el resultado de una transición depende únicamente del resultado de la transición previa.

Una *cadena de Markov* se describe por medio de un conjunto de probabilidades condicionales $P_{ij}(k-1,k)$ para cada par de resultados (i,j) donde $P_{ij}(k-1,k)$ es la probabilidad de que el resultado del experimento k -ésimo sea j , supuesto que el resultado del experimento $(k-1)$ -ésimo sea i .

Si se define como $a_i(k)$ la probabilidad de obtener como resultado i en el k -ésimo intento, se podrá calcular $a_i(k)$ mediante la siguiente expresión:

$$a_i(k) = \sum_{l=1}^L a_l(k-1) \cdot P_{li}(k-1,k) \quad k = 1, 2, \dots \quad (6.30)$$

siendo L el número de posibles soluciones.

Si se denota como $X(k)$ el resultado del experimento k , entonces:

$$P_{ij}(k-1,k) = \Pr\{X(k)=j \mid X(k-1)=i\} \quad (6.31)$$

y que:

$$a_i(k) = \Pr\{X(k)=i\} \quad (6.32)$$

Si las probabilidades condicionales no dependen de k , la correspondiente cadena de Markov se denomina *homogénea*, y en caso contrario, *no homogénea*.

En el caso de los algoritmos SA, la probabilidad condicional $P_{ij}(k-1,k)$ representa la probabilidad de que la k -ésima transición sea una transición de la configuración i a la j . De esta forma, $X(k)$ es la configuración obtenida después de k transiciones. A la vista de esto, $P_{ij}(k-1,k)$ se denomina *probabilidad de transición* y a la matriz $|S| \times |S|$ formada por $P_{ij}(k-1,k)$, *matriz de transición*.

Las probabilidades de transición dependen del valor del parámetro de control T (de la temperatura del sistema), de esta forma, si se mantiene constante T la correspondiente cadena de Markov es homogénea y la matriz de transición $P=P(T)$ se puede definir como:

$$P_{ij}(T) = \begin{cases} G_{ij}(T)A_{ij}(T) & \forall j \neq i \\ 1 - \sum_{l=1, l \neq i}^s G_{il}(T)A_{il}(T) & j = i \end{cases} \quad (6.33)$$

Según la ecuación (6.33) cada probabilidad de transición se define como el producto de dos probabilidades condicionales: la *probabilidad de generación* $G_{ij}(T)$, que proporciona la probabilidad de generar la configuración j a partir de la configuración i , y la *probabilidad de aceptación* $A_{ij}(T)$, que indica la probabilidad de aceptar la configuración j generada a partir de la configuración i . Las respectivas matrices $G(T)$ y $A(T)$ se denominan respectivamente matriz de generación y matriz de aceptación.

De la definición (6.33) se deduce que la matriz $P(T)$ es una matriz estocástica, es decir:

$$\forall i \quad \sum_j P_{ij}(T) = 1 \quad (6.34)$$

Utilizar la expresión (6.33), supone una generalización de la idea de algoritmo SA, ya que éste sería un caso particular de un tipo de algoritmos más general, siendo en este caso, $G_{ij}(T)$ una distribución uniforme de la vecindad (las transiciones se realizan escogiendo aleatoriamente una configuración vecina j de la configuración actual i), y $A_{ij}(T)$ está dada por el algoritmo Metrópolis.

Puesto que el parámetro T varía en el transcurso del algoritmo, se pueden distinguir dos tipos de formulaciones del mismo:

- a) *Algoritmo homogéneo*: el algoritmo es descrito por una serie de cadenas de Markov homogéneas. Cada una de estas cadenas es generada para un valor fijo de la Temperatura. Esta T se disminuye progresivamente entre cadenas consecutivas.
- b) *Algoritmo no homogéneo*: el algoritmo es descrito por una única cadena de Markov. El valor de T se disminuye entre transiciones consecutivas, lo que equivale a considerar que se realiza el enfriamiento a través de una serie de escalones de longitud unidad.

El algoritmo S.A. obtiene un mínimo global si, después de un número de transiciones (normalmente bastante elevado, de valor K), se verifica la siguiente relación:

$$\Pr\{X(K) \in S_{opt}\} = 1 \quad (6.35)$$

Donde: S_{opt} es el conjunto de configuraciones de los mínimos globales.

Se puede demostrar que el algoritmo homogéneo presenta convergencia asintótica es decir

$$\lim_{K \rightarrow \infty} \Pr \{ X(K) \in S_{\text{opt}} \} = 1 \text{ si:}$$

- Cada cadena de Markov es de longitud infinita.
- Se verifican ciertas condiciones en las matrices $A_{ij}(t)$ y $G_{ij}(t)$
- $\lim_{l \rightarrow \infty} T_l = 0$ donde T_l es la temperatura en la l -ésima cadena de Markov.

Para el algoritmo no homogéneo se pueden establecer otro conjunto de condiciones que garantizan la convergencia. En (van Laarhoven y Aarts 1987) se puede encontrar el desarrollo matemático que justifica las afirmaciones anteriores.

6.3.2.2 Implementación del algoritmo.

La implementación habitual del algoritmo es mediante una secuencia de cadenas de Markov homogéneas de longitud finita con valores decrecientes del parámetro de control o temperatura.

Como se ha mencionado previamente, los parámetros que van a definir el comportamiento del algoritmo, constituyen el esquema de enfriamiento, y son:

- Temperatura inicial.
- Temperatura final (criterio de congelación).
- Condición de equilibrio (longitud de la cadena de Markov).
- Ley de evolución de la temperatura.

6.3.2.2.1 Cálculo de la temperatura inicial

La temperatura inicial debe ser independiente de la solución inicial y lo suficientemente alta como para aceptar casi libremente todas las soluciones del entorno. Esta decisión es la primera a tomar en el diseño del algoritmo y se basa en reglas semi-empíricas. En la bibliografía se pueden encontrar diferentes sistemas para determinarla.

Por ejemplo, escoger T_0 de tal forma que prácticamente sean aceptadas todas las transiciones, es decir que la probabilidad de transición $P = e^{(-\Delta C/T_0)} \simeq 1$. Aunque los dos mecanismos más empleados para calcular la temperatura inicial son los siguientes.

(Kirkpatrick, Gelatt y Vecchi 1983) en su artículo proponen una regla empírica, basada en el concepto de *coeficiente de aceptación* χ , definido como el cociente entre transiciones aceptadas e intentadas.

El mecanismo de cálculo de la T_0 es el siguiente: se selecciona una temperatura muy elevada, y se realizan un número predeterminado de transiciones, calculando el valor de χ ,

si χ es menor de una cierta cantidad, por ejemplo 0.8, entonces se dobla el valor de T_0 , procediendo así sucesivamente hasta verificar la condición impuesta.

(Kouvelis, Chiang y Fitzsimmons 1992), utilizan la expresión $T_0 = \frac{\overline{\Delta C}^{(+)}}{\ln(\chi_0^{-1})}$ donde se calcula el incremento de coste medio positivo (los incrementos negativos no se consideran) de una serie de transiciones prefijado (generalmente igual al tamaño de la vecindad) para un determinado valor de χ_0 (0.8 es el valor propuesto por los autores).

En (Dowland y Adenso Diaz 2003) se pueden encontrar algunas otras reglas para la determinación de la temperatura inicial del algoritmo.

6.3.2.2.2 Temperatura final (criterio de congelación).

El segundo de los parámetros a fijar en el algoritmo es la condición de parada, que se puede establecer de diferentes maneras:

- Fijando un número determinado de valores de T para los cuales se ejecuta el algoritmo.
- Fijar un determinado número de escalones sin que se produzca un cambio en la configuración obtenida.
- Establecer un coeficiente de aceptación χ mínimo, de tal forma que en caso de no alcanzarse se produzca la parada del algoritmo.

6.3.2.2.3 Condición de equilibrio (Longitud de la cadena de Markov)

La elección más sencilla para L_k , longitud de la k -ésima cadena de Markov, es elegir un valor dependiente (de forma polinómica) del tamaño del problema. Así, L_k es independiente de k . Existen propuestas más elaboradas, en las que se establece que para cada valor T_k se debería realizar un número mínimo de transiciones. Entonces en este caso se determina L_k de tal forma que el número mínimo de transiciones sea η_{min} (siendo η_{min} un número fijo). Sin embargo al aproximarse T al valor 0, las transiciones son aceptadas cada vez con una probabilidad menor de tal forma que $L_k \rightarrow \infty$ si $T_k \rightarrow 0$. Por ello, L_k debe estar acotado superiormente por una cierta constante \bar{L} , para evitar cadenas de Markov excesivamente largas para bajos valores de T .

En esta línea (Kirkpatrick, Gelatt y Vecchi 1983) proponen que el valor superior de la longitud, $\bar{L} = n$ siendo n el número de variables a resolver. Otra opción es tomar $\bar{L} = m \cdot R$ como un múltiplo (m) del tamaño de la de vecindad (R).

6.3.2.2.4 Ley de evolución de la temperatura.

Existen diferentes leyes de evolución de temperatura que se clasifican en función de su complejidad. Un primer grupo agruparía a los esquemas sencillos de enfriamiento. Se pueden englobar aquí leyes de tipo geométrico:

$$T_m = c \cdot T_{m-1} \quad (6.36)$$

Pudiendo fijar el valor de c en función de que se quiera un enfriamiento lento (el más empleado) $c \in [0.8-0.99]$ o un enfriamiento más rápido $c \in [0.5-0.79]$.

También se pueden encontrar leyes de tipo potencial:

$$T_m = c^m \cdot T_0 \quad (6.37)$$

con lo que se obtiene una curva de enfriamiento, produciéndose un enfriamiento más rápido a temperaturas elevadas, que posteriormente se hace más lento a bajas temperaturas.

Otro tipo de ley de enfriamiento que aparece en la bibliografía es la de establecer a priori un número determinado de escalones (K), de tal forma que se mantiene el salto de temperatura constante siguiendo la siguiente expresión:

$$T_m = \frac{K-m}{m} \cdot T_0 \quad (6.38)$$

Otros autores como (Maniezzo y Colorni 1995) proponen leyes de enfriamiento ligeramente diferentes a las anteriores:

$$\begin{aligned} T_{m+1} &= \frac{T_m}{1+c \cdot T_m} \\ T_{m+1} &= \frac{T_0}{1+c \cdot m} \end{aligned} \quad (6.39)$$

Al margen de los esquemas sencillos, en (van Laarhoven y Aarts 1987) se pueden encontrar un conjunto de propuestas que se podría definir como “esquemas complejos de enfriamiento” en los que la formulación matemática es mucho más compleja.

6.3.3 Algoritmo Annealing Multiobjetivo

El algoritmo que se ha empleado en el presente trabajo pertenece a la familia MOSA (*Multi Objective Simulated Annealing*) comentados en capítulos anteriores aunque con ligeras modificaciones realizadas sobre los allí expuestos.

El punto de partida para el algoritmo empleado es el GHC-Aleatorio introducido por (Gonzalez 2005), sobre el que se hacen algunas modificaciones para mejorar su rendimiento. En el mismo trabajo, el autor introduce otros dos algoritmos (GHC-Pareto y GHC-Lógico) que variaban únicamente en la forma en la que se obtenían las nuevas soluciones en cada uno de los lanzamientos del algoritmo (tras verificar el criterio de estabilidad).

El esquema del algoritmo es el mostrado en la Figura 6.3.3, y la explicación del funcionamiento del mismo se detalla en las siguientes páginas.

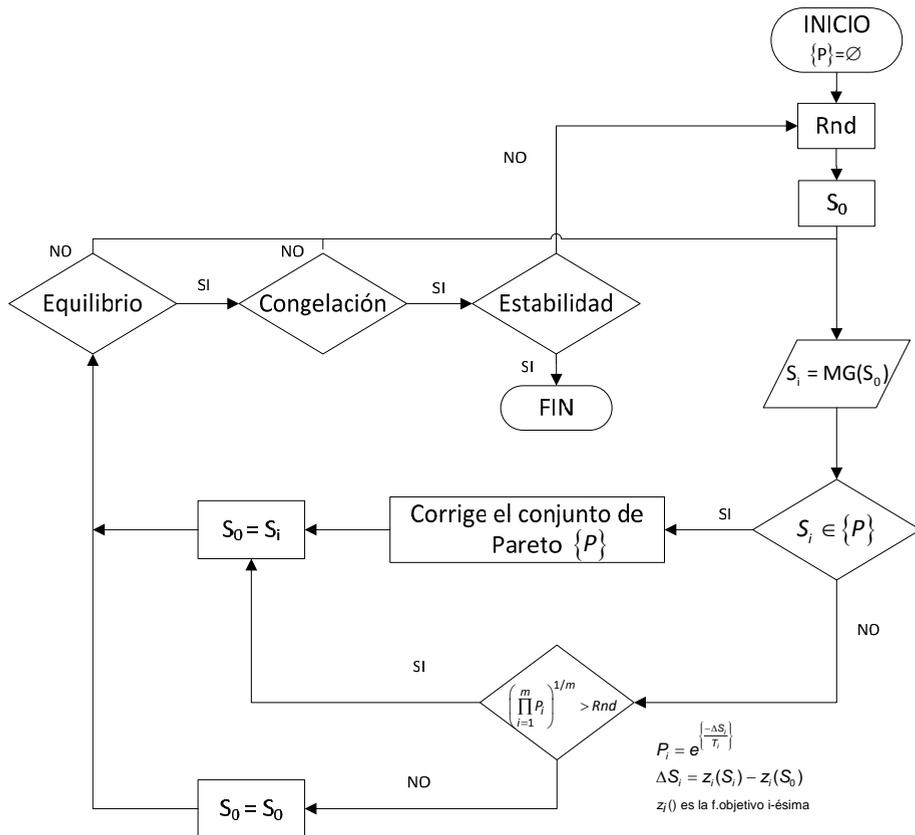
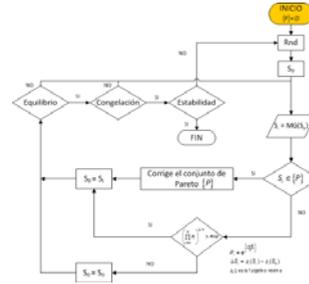
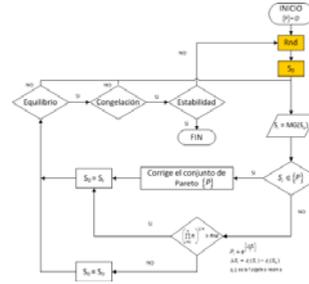


Figura 6.3.3 Algoritmo Annealing Multiobjetivo propuesto.

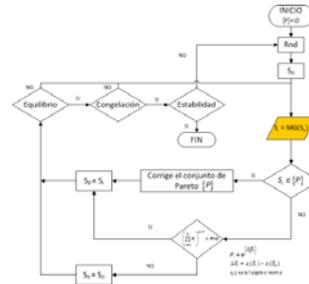
1. Inicialización del conjunto de Pareto: Al iniciar el algoritmo el conjunto de Pareto $\{P\}$ está vacío, con lo cual se introducirá la primera solución generada aleatoriamente en él.



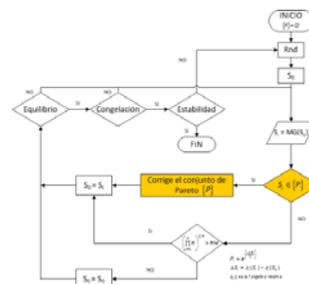
2. Generar solución inicial S_0 : Se construye una solución inicial, generando de forma aleatoria una secuencia de bandas y actividades y colocándolos sobre el recinto mediante una curva guiada.



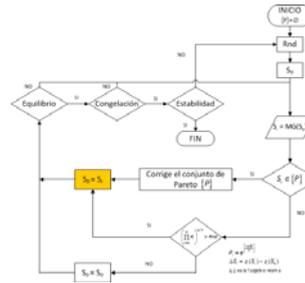
3. Elegir solución S_i de la vecindad: Se genera la vecindad, seleccionando el mecanismo (bandas o actividades) y se selecciona aleatoriamente una solución S_i de ella.



4. Comprobar si entra en $\{P\}$: Se comprueba si S_i entra a formar parte del conjunto de Pareto $\{P\}$, corrigiendo entonces la frontera, eliminando los elementos dominados o sumando la solución si son indiferentes. Si no entra ir a 6.



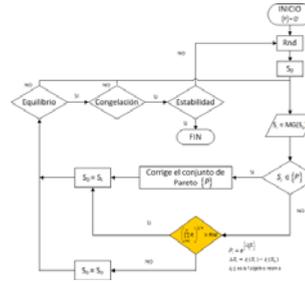
5. Hacer S_i la solución actual: Al corregir la frontera de Pareto, se acepta la solución y se convierte en la solución actual ($S_0=S_i$).



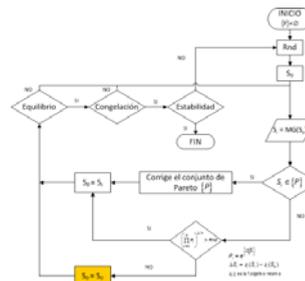
6. Calcular la probabilidad de transición: Si la solución S_i no corrige la frontera de Pareto, se aceptará con una probabilidad combinada de los m objetivos, según:

$$\left(\prod_{i=1}^m e^{\left\{ \frac{-\Delta S_i}{T_i} \right\}} \right)^{1/m} > Rnd$$

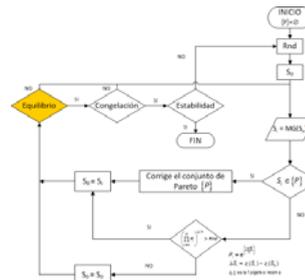
Si se acepta se va a 5, sino a 7.



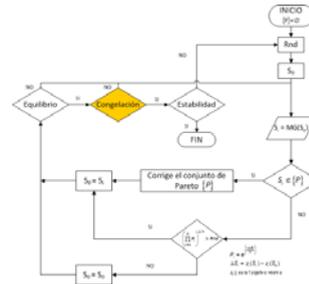
7. Mantener la solución actual: No se acepta S_i como solución actual, manteniéndose S_0 para la siguiente iteración.



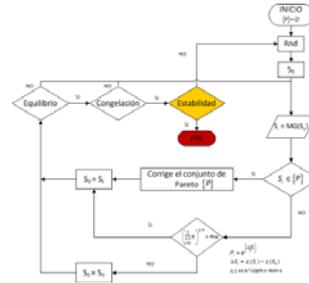
8. Comprobar el criterio de equilibrio: Una vez establecida la nueva S_0 (que puede ser igual o diferente que la precedente se comprueba si se verifica el criterio de equilibrio. En caso afirmativo, se desciende un escalón de T^a , sino se vuelve a 3.



9. Comprobar el criterio de congelación: Una vez descendido el escalón de T^a , se comprueba el criterio de congelación, en caso negativo se va a 3. Si el algoritmo se ha "congelado" se pasa a 10.



10. Comprobar el criterio de estabilidad: ¿Es la frontera de Pareto {P} estable? en caso afirmativo, el algoritmo finaliza, y si la frontera no es estable, se relanza desde una solución aleatoria (ir a 2).



6.3.3.1 Temperatura inicial del algoritmo

El primer parámetro a fijar es la temperatura inicial del algoritmo. Una característica fundamental de la aproximación multiobjetivo realizada es precisamente ese carácter multicriterio del propio algoritmo diseñado, pues se establece una temperatura inicial para cada uno de los objetivos que se optimice en cada uno de los lanzamientos del mismo.

El esquema cálculo de la temperatura inicial es la empleada por Kouvelis, que fue comentada en 6.3.2.2.1 y que se formula a continuación para cada uno de los m objetivos.

$$T_{0i} = \frac{\overline{\Delta C_i^{(+)}}}{\ln(\chi_0^{-1})} \tag{6.40}$$

Como valor de χ_0 se impone 0.9, que es ligeramente superior al propuesto por (Kouvelis, Chiang y Fitzsimmons 1992), que era de 0.8. Este coeficiente se hace algo mayor para aumentar la probabilidad de aceptación de soluciones cuyo incremento en la función objetivo sea contrario al sentido de optimización, en las etapas iniciales del proceso.

Para realizar el cálculo de las temperaturas iniciales se emplea el generador de soluciones, que lanza configuraciones en las que tanto la secuencia de actividades como de bandas es aleatoria, evaluando el incremento de cada una de los m objetivos a optimizar respecto a la solución inicial. Si el incremento del objetivo es de mejora (positivo o negativo, en función del objetivo), no se considera, y si empeora sí que se acumula en el cálculo. El número de soluciones generadas para determinar la temperatura inicial de cada uno de los m objetivos es igual al tamaño de la vecindad de la solución inicial.

Por tanto se calcula la temperatura inicial de cada objetivo en cada uno de los lanzamientos independientes del algoritmo, pues varía en función de la solución inicial que se haya obtenido y del tamaño de la vecindad de la misma. En la Tabla 6.3.1, se adjuntan los resultados del cálculo de T_i obtenidos sobre 100 lanzamientos del algoritmo.

| | Media | Mínimo | Máximo | Desviación |
|----------------------------|--------|---------|----------|------------|
| Coste entre centros | 5968,8 | 2059,3 | 16427,32 | 2428,81 |
| Compacidad mínima | 0,68 | 0,11 | 1,6 | 0,32 |
| Coste EDIST | 5617,3 | 1644,21 | 14290,52 | 2253,6 |
| Robustez mínima | 0,51 | 0,08 | 1,59 | 0,31 |
| Circulación | 0,54 | 0,09 | 1,04 | 0,2 |
| FMP | 0,28 | 0,04 | 0,61 | 0,11 |
| SRF | 0,22 | 0,06 | 0,68 | 0,11 |
| Forma mínima | 0,28 | 0,03 | 0,93 | 0,2 |

Tabla 6.3.1 Valores de T_i para 100 lanzamientos del algoritmo.

6.3.3.2 Esquema de enfriamiento

Como esquema de enfriamiento del algoritmo se emplea la siguiente ley de evolución de la temperatura de la ecuación (6.41), en la que se reduce la temperatura inicial T_0 de forma escalonada:

$$T_{i+1} = c \cdot T_i \tag{6.41}$$

El parámetro c se denomina *Coficiente de enfriamiento* y se empleará el valor 0.8, el mismo se propone en (Gonzalez 2005), donde se obtuvo mediante el lanzamiento de 1000 iteraciones del algoritmo sobre el problema AB20 con los resultados mostrados la Figura 6.3.4, aplicando posteriormente éste valor en su investigación, con resultados aceptables.

Se selecciona el valor de $c = 0.8$ por ser el que proporciona el valor de mínimo coste y coste promedio así como un tiempo de ejecución aceptable para el desarrollo de la investigación.

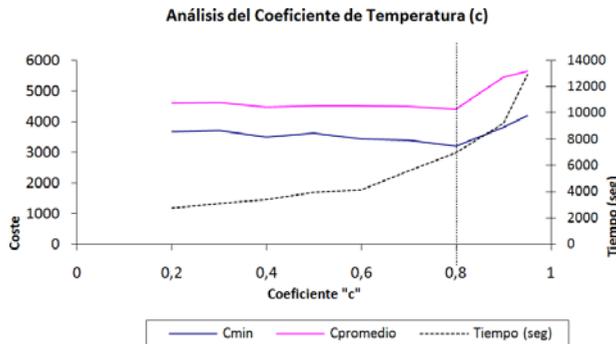


Figura 6.3.4 Determinación del coeficiente de enfriamiento de (Gonzalez 2005).

Un ejemplo de la ley de evolución de la temperatura para el criterio coste entre centros, con una temperatura inicial $T_0=5968$ (la media, comentada anteriormente), una vecindad promedio de 200 configuraciones y un coeficiente de enfriamiento $c=0.8$ se muestra en la Figura 6.3.5.

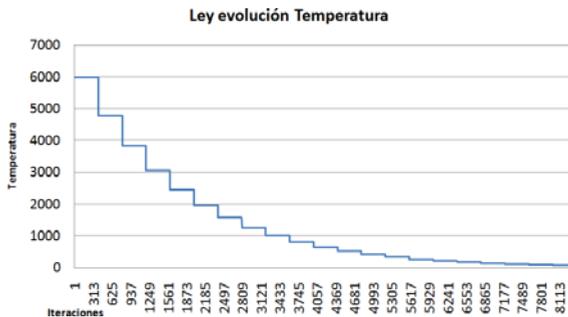


Figura 6.3.5 Ejemplo de esquema de enfriamiento.

6.3.3.3 Condición de equilibrio en un escalón de temperatura

El siguiente parámetro a fijar es el de la condición de equilibrio para cada uno de los escalones de temperatura del algoritmo Annealing multiobjetivo. El criterio viene dado por la longitud de la cadena de Markov a cada temperatura y depende del tamaño de la vecindad (Vec) de la solución inicial.

Según (Contero 1995), basándose en (Kouvelis, Chiang y Fitzsimmons 1992) el criterio de equilibrio viene dado por las siguientes dos condiciones:

1. Que el número máximo de intercambios aceptados (N_{accept}) a una temperatura dada sea igual a:

$$N_{\text{accept}} = \text{LENPERCENT} \cdot \text{Vec} \quad (6.42)$$

Donde LENPERCENT es un parámetro marcado por Kouvelis y que establece en 0.95.

2. El número total de intentos de cambio (N_{int}) realizados a una temperatura sea:

$$N_{\text{int}} = 2 \cdot \text{Vec} \quad (6.43)$$

Estas dos condiciones son las que determinarán en cada escalón de temperatura la longitud de la cadena de Markov, fijando de esta forma la condición de equilibrio.

En el caso de la presente investigación, como el tamaño de la vecindad depende del número de actividades (n) y del número de bandas (nb), según (6.23) las dos condiciones de equilibrio serán:

1. Intercambios aceptados: $N_{\text{accept}} \geq 0.95 \cdot \left(\frac{n \cdot (n-1)}{2} + (3 \cdot nb - 2) \right)$
2. Intercambios intentados: $N_{\text{int}} \geq 2 \cdot \left(\frac{n \cdot (n-1)}{2} + (3 \cdot nb - 2) \right)$

6.3.3.4 Criterio de congelación

Como criterio de congelación se emplea el utilizado por (Contero 1995) y (Gonzalez 2005) que tiene, como en el caso del criterio de equilibrio una doble comprobación:

1. *Coficiente de congelación (C_{CONG}):* Se establece un porcentaje mínimo de intentos de intercambio aceptados ($\%_{accept}$) a una Temperatura dada. Si el porcentaje de intercambios aceptados es menor del coeficiente de congelación, se considera que el algoritmo ha llegado a la congelación. En caso contrario se baja el escalón de temperatura, siguiendo la ley (6.41).

En esta investigación, al igual que en las anteriormente citadas, se emplea un $C_{CONG} = 1\%$, por tanto al final de cada escalón se comprobará (6.44).

$$\frac{N_{accept}}{N_{int}} \leq C_{CONG} = 1\% \tag{6.44}$$

2. *Número máximo de escalones (Esc_{max}):* Para limitar la duración temporal del algoritmo se puede establecer un número máximo de escalones de temperatura, este parámetro tiene una difícil implementación, si no se conoce cuál es el comportamiento del algoritmo sobre el problema a optimizar. Uno de los objetivos a resolver en el presente trabajo es determinar cuál es el número máximo de escalones de temperatura del algoritmo, con la finalidad de imponer una condición en futuras aplicaciones del algoritmo a otros problemas de distribución en planta.

Una vez desarrollado el plan experimental, sobre el problema de AB20 y los diferentes indicadores comentados con anterioridad, se obtienen, sobre 5000 lanzamientos del algoritmo los valores de número de escalones mostrados en la siguiente tabla.

| | Número de Escalones | | |
|-------------------|---------------------|--------------|--------------|
| | Promedio | Mínimo | Máximo |
| CTC-Circulación | 24,9 | 20,3 | 29,5 |
| CTC-Compacidad | 26,9 | 22,7 | 31,7 |
| CTC-Forma | 26,9 | 22,5 | 31,8 |
| CTC-FMP | 26,2 | 22,3 | 30,9 |
| CTC-Robustez | 27,3 | 23,3 | 32,3 |
| CTC-SRF | 25,7 | 25,7 | 22 |
| EDIST-Circulación | 25 | 20,5 | 29,5 |
| MEDIO | 26.13 | 22.47 | 29.67 |

Tabla 6.3.2 Tamaños de escalón en el algoritmo multiobjetivo empleado.

Con estos datos parece razonable plantear, para futuras investigaciones un número de escalones de temperatura $Esc_{max} = 27$, que es el tamaño promedio obtenido en la presente investigación

6.3.3.5 Criterio de estabilización

El criterio de estabilización tiene en consideración la variación de la frontera de Pareto. Este criterio establece que, si después de un determinado número de ciclos del algoritmo no se produce una variación de la frontera de Pareto, se produzca la parada del mismo.

En (Gonzalez 2005) se puede encontrar un estudio de un parámetro de estabilización aplicado al problema de distribución en planta. En la referencia, el autor plantea un algoritmo con "memoria", pues se lanza una única vez y el mismo acumula la frontera de Pareto durante toda la ejecución. Es por este motivo que el valor del parámetro de estabilización estudiado es de 25-50-100-150 lanzamientos sin variación de la frontera. El autor llega a la conclusión de que el parámetro de estabilidad 100 es el más apropiado.

En la presente investigación se valora la posibilidad de realizar el lanzamiento independiente del algoritmo, acortando el parámetro de estabilización y realizando relanzamientos partiendo de conjunto de Pareto $(P) = \emptyset$.

Se plantea un parámetro de estabilidad más corto, de 5 ciclos del algoritmo sin que se produzca mejora en la frontera de Pareto. Esta decisión viene determinada por lo comentado en el párrafo anterior, se persigue diversificar la búsqueda haciendo lanzamientos independientes partiendo de una frontera vacía.

6.4 MECÁNICA DEL PROCESO DE OPTIMIZACIÓN

Una vez conocido el algoritmo que se va a emplear para la optimización de soluciones, así como los valores de los diferentes parámetros que lo controlan, el último paso a dar es el relativo a la forma en la que se va a fijar todo el proceso de optimización.

Se describen dos mecánicas en el proceso de optimización del algoritmo multiobjetivo mediante *Simulated Annealing* (en realidad con cualquier otro algoritmo también), siempre que se emplee la frontera de Pareto.

6.4.1 Experimentos concatenados

Una primera opción, que se puede encontrar en (Gonzalez 2005), realiza una serie de experimentos concatenados, donde la frontera de Pareto de cada nuevo lanzamiento (arranque desde una solución generada aleatoriamente) es la obtenida del lanzamiento anterior.

El esquema de este procedimiento se muestra en la Figura 6.4.1, donde cada nuevo ciclo se corresponde con la generación de una solución aleatoria nueva (ver punto 2 de 0)

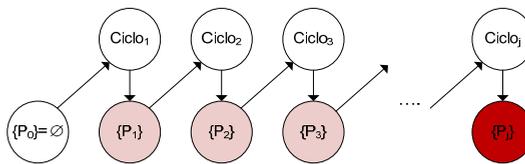


Figura 6.4.1 Esquema de experimento concatenado.

Este procedimiento no rearranca desde una frontera vacía, por tanto es más rápido que el explicado más abajo.

El criterio de parada en este caso se corresponde con el criterio de estabilidad del algoritmo comentado en los puntos anteriores, y el resultado obtenido en el mismo es directamente la frontera de Pareto del problema.

6.4.2 Experimentos independientes

La segunda opción que se contempla a la hora de diseñar el plan experimental es realizar una mecánica del proceso de optimización que no permita recuperar, para emplear como punto de partida, los valores de la frontera de Pareto del experimento anterior.

De esta forma, cada experimento es independiente, y como resultado se obtiene una frontera de Pareto parcial, que debe ser fusionada con la frontera de Pareto global obtenida de los experimentos anteriores.

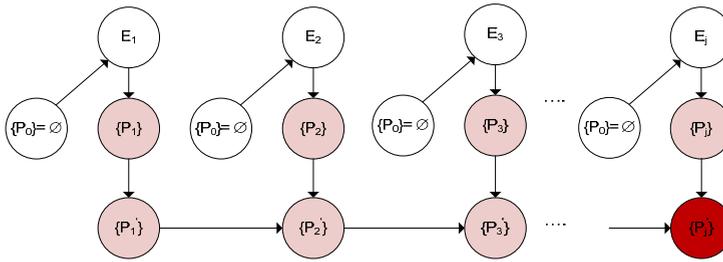


Figura 6.4.2 Esquema de experimentos independientes.

El esquema de esta mecánica se muestra en la Figura 6.4.2, en la que se puede ver como en cada experimento (E_1, \dots, E_j) se parte desde un conjunto de Pareto vacío, obteniendo la frontera de Pareto de cada experimento (P_1, \dots, P_j) para posteriormente fusionarla con la inmediatamente anterior, obteniendo la frontera de Pareto global (P_1', \dots, P_j').

Este procedimiento es más lento que el anterior, pues el partir de un conjunto de Pareto vacío hace que el número de soluciones aceptadas siempre sea mayor y por tanto la convergencia hacia la frontera de Pareto sea más laboriosa.

6.4.2.1 Criterio de parada del proceso de optimización

Una de las características a fijar, si se emplea este tipo de procedimiento, es el *criterio de parada* del proceso de optimización, es decir, en qué momento se debe dejar de lanzar nuevos experimentos y parar el proceso.

El criterio que se empleará en el presente trabajo es, al igual que en el caso del criterio de estabilidad, que se realicen 5 experimentos consecutivos sin que se produzca variación en la frontera. Destacar, que en los resultados obtenidos, el promedio de lanzamientos por experimento fue de 19, por tanto la parada del proceso tendrá lugar cuando se hayan realizado, $19 \cdot 5 = 95 \cong 100$, que es el criterio de estabilización empleado por (Gonzalez 2005).

6.4.2.2 Depuración de la frontera de Pareto

En el presente trabajo se genera una rutina que permita realizar la comparación entre dos fronteras de Pareto, fusionando ambas para obtener la frontera global de las dos. Esta rutina permite determinar si cada punto de la nueva frontera a fusionar es dominado (en cuyo caso es eliminado), domina a otros puntos (en cuyo caso entra en el conjunto, eliminando aquellos puntos a los que ha dominado) o es indiferente (entrando directamente en el conjunto).

7 PLAN EXPERIMENTAL. RESULTADOS OBTENIDOS

7.1 EL PROBLEMA DE ARMOUR Y BUFFA DE 20 ACTIVIDADES. AB20

Este problema test fue propuesto en (Armour y Buffa 1963) para ilustrar el funcionamiento del algoritmo CRAFT, propuesto por los autores. El recinto propuesto por los autores es de dimensiones fijas y rectangular ($R=1.5$), de tamaño 300×200 unidades de longitud. Los autores emplean el sistema métrico anglosajón, utilizando los pies como unidades de longitud y los pies cuadrados como unidad de superficie.

La superficie ocupada por cada una de las 20 actividades se muestra en la Tabla 7.1.1. Tal y como se puede observar la suma total del área de todas las actividades es igual a la superficie total del recinto rectangular considerado, por tanto no hay holgura en la colocación de las actividades.

| Nº Actividad | Nombre Actividad | Área (100-pies ²) | Nº Actividad | Nombre Actividad | Área (100-pies ²) |
|-----------------|---------------------|----------------------------------|-----------------|---------------------|----------------------------------|
| 1 | A | 27 | 11 | L | 60 |
| 2 | B | 18 | 12 | M | 42 |
| 3 | C | 27 | 13 | N | 18 |
| 4 | D | 18 | 14 | P | 24 |
| 5 | E | 18 | 15 | R | 27 |
| 6 | F | 18 | 16 | S | 75 |
| 7 | G | 9 | 17 | T | 64 |
| 8 | H | 9 | 18 | U | 41 |
| 9 | J | 9 | 19 | V | 27 |
| 10 | K | 24 | 20 | W | 45 |

Tabla 7.1.1 Superficie de cada una de las 20 actividades del problema AB20.

El dominio de partida está discretizado tomando un módulo cuadrado de 100 pies² de superficie (10·10 pies). Este problema es uno de los más empleados en la bibliografía como problema test para comparar la eficacia de algoritmos por autores que trabajan en la resolución del problema de distribución en planta con actividades de área desigual y en algunos casos con un enfoque multiobjetivo.

Este problema se puede considerar de tamaño grande y su naturaleza es del tipo FLP con actividades de área desigual. En el planteamiento original de Armour y Buffa no se consideran aspectos de calidad geométrica a excepción del control de agregación de actividades y la métrica empleada es la Manhattan.

El tamaño del espacio de soluciones de este problema considerando su aplicación en un modelo geométrico discreto es, incluyendo las configuraciones disgregadas o no factibles:

$$N = C_c^{c_1} \cdot \prod_{i=2}^c C_{c_i}^{c_i} = \frac{c!}{\prod_{i=1}^n c_i!} = \frac{600!}{\prod_{i=1}^{20} c_i!} \approx 10^{715} \quad (7.1)$$

Donde: c es el número de casillas de la discretización ($n_a \times n_h$).

c_i es el número de casillas de la actividad i -ésima.

n es el número de actividades.

En la Tabla 7.1.2 se detallan los flujos interdepartamentales entre las diferentes actividades del problema, con algunos valores corregidos del artículo original, y obtenidos de (Contero Gonzalez 1995) y (Wang, Hu y Ku 2005) pues en el artículo original no estaban bien consignados.

| | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | 15 | 16 | 17 | 18 | 19 | 20 |
|----|------|------|------|------|------|------|------|------|------|------|------|------|------|------|------|------|------|------|-------|-------|
| 1 | 0 | 1,8 | 1,2 | 0 | 0 | 0 | 0 | 0 | 0 | 1,04 | 1,12 | 0 | 0 | 1,2 | 0 | 0 | 0 | 0 | 0 | 0 |
| 2 | 1,8 | 0 | 0,96 | 24,5 | 0,78 | 0 | 14 | 0 | 1,2 | 1,35 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 6,9 | 0 |
| 3 | 1,2 | 0,96 | 0 | 0 | 0 | 2,21 | 0 | 0 | 3,15 | 3,9 | 0 | 0 | 0 | 13,1 | 0 | 0 | 0 | 0 | 13,65 | 0 |
| 4 | 0 | 24,5 | 0 | 0 | 1,08 | 5,7 | 7,5 | 0 | 2,34 | 0 | 0 | 1,4 | 0 | 0 | 0 | 0 | 0 | 1,5 | 15,75 | 0 |
| 5 | 0 | 0,78 | 0 | 1,08 | 0 | 0 | 2,25 | 1,35 | 0 | 1,56 | 0 | 0 | 0 | 0 | 1,35 | 0 | 0 | 0 | 0 | 0 |
| 6 | 0 | 0 | 2,21 | 5,7 | 0 | 0 | 6,15 | 0 | 0 | 0 | 0 | 0,45 | 0 | 0 | 0 | 0 | 0 | 1,05 | 0 | 0 |
| 7 | 0 | 14 | 0 | 7,5 | 2,25 | 6,15 | 0 | 24 | 0 | 1,87 | 0 | 0 | 0 | 0,96 | 0 | 0 | 0 | 1,65 | 0 | 3,75 |
| 8 | 0 | 0 | 0 | 0 | 1,35 | 0 | 24 | 0 | 0 | 0 | 0 | 0 | 0,6 | 0 | 0 | 0 | 0 | 0 | 7,5 | 33,45 |
| 9 | 0 | 1,2 | 3,15 | 2,34 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 7,5 | 0 | 0 | 7,5 | 0 | 0 | 0 |
| 10 | 1,04 | 1,35 | 3,9 | 0 | 1,56 | 0 | 1,87 | 0 | 0 | 0 | 0,36 | 12 | 0 | 18,6 | 1,92 | 0 | 0 | 0 | 5,25 | 0 |
| 11 | 2,25 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0,36 | 0 | 2,25 | 0 | 3 | 0,96 | 22,5 | 0 | 0 | 0 | 0 |
| 12 | 0 | 0 | 0 | 1,4 | 0 | 0,45 | 0 | 0 | 0 | 12 | 2,25 | 0 | 0 | 0 | 1,65 | 0 | 15 | 0 | 8,4 | 0 |
| 13 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0,6 | 0 | 0 | 0 | 0 | 0 | 8 | 1,04 | 6 | 0 | 0 | 0 | 0 |
| 14 | 1,2 | 0 | 13,1 | 0 | 0 | 0 | 0,96 | 0 | 7,5 | 18,6 | 3 | 0 | 8 | 0 | 9,75 | 0 | 0 | 0,9 | 0 | 0 |
| 15 | 0 | 0 | 0 | 0 | 1,35 | 0 | 0 | 0 | 0 | 1,92 | 0,96 | 1,65 | 1,04 | 9,75 | 0 | 0 | 5,25 | 0 | 0 | 0 |
| 16 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 22,5 | 0 | 6 | 0 | 0 | 0 | 12 | 0 | 0 | 0 |
| 17 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 7,5 | 0 | 0 | 15 | 0 | 0 | 5,25 | 12 | 0 | 0 | 7,5 | 0 |
| 18 | 0 | 0 | 0 | 1,5 | 0 | 1,05 | 1,65 | 0 | 0 | 0 | 0 | 0 | 0 | 0,9 | 0 | 0 | 0 | 0 | 4,65 | 0 |
| 19 | 0 | 6,9 | 13,7 | 15,8 | 0 | 0 | 0 | 7,5 | 0 | 5,25 | 0 | 8,4 | 0 | 0 | 0 | 0 | 7,5 | 4,65 | 0 | 0 |
| 20 | 0 | 0 | 0 | 0 | 0 | 0 | 3,75 | 33,5 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |

Tabla 7.1.2 Matriz de flujos entre actividades W_{ij} (\$/año·100 pies).

Otros problemas test empleados en la bibliografía para contrastar los resultados de las distintas metodologías propuestas son: el de (Francis y White 1974) que es un problema de 13 actividades, una de las cuales es fija y sin flujo con el resto y el ejemplo 8.2 del libro de (Tompkins, White y Tanchoco 2003), de 8 actividades, una de las cuales (*dummy*) se corresponde a la holgura del dominio, por tanto tampoco tiene relación con el resto de actividades.

Aunque estos problemas en su planteamiento inicial no son multiobjetivo y se presentaron para ilustrar diferentes heurísticas y algoritmos de resolución del problema monoobjetivo (únicamente con coste), en los últimos años se han utilizado como referencia de planteamientos multiobjetivo.

El problema de Armour y Buffa es el más empleado en la bibliografía como problema test, puesto que es un problema de gran tamaño, no obstante, los otros dos problemas completan aspectos del problema FLP no abordados por aquel, tales como pueden ser las actividades fijas sin flujo que permiten configurar contornos irregulares y recintos no convexos, aspectos que se desarrollarán en trabajos futuros.

La dominancia del flujo f se considera como un índice de la facilidad del problema (Das 1993) y se define como el coeficiente de variación, expresado en tanto por ciento, de los elementos de la matriz de flujo w_{ij} . Y se calcula según la ecuación (7.2), donde n es el número de actividades:

$$f = 100 \cdot \frac{\sigma}{F}; \quad (7.2)$$

$$F = \frac{2}{n \cdot (n-1)} \sum_{i=1}^n \sum_{j=i+1}^n w_{ij}; \quad \sigma = \left[\frac{2}{n \cdot (n-1)} \sum_{i=1}^n \sum_{j=i+1}^n (w_{ij} - F)^2 \right]^{1/2}$$

Valores de baja dominancia del flujo f ponen de manifiesto la dificultad de encontrar el óptimo al tratarse topografías llanas de la función de objetivo, mientras que valores elevados de la dominancia de flujo indican la existencia de trayectorias preeminentes de flujo, que orientan a la ordenación y a la distribución en planta de las actividades.

A partir de la dominancia del flujo y del número de actividades se puede establecer para cada problema su índice de complejidad C_f , establecido en (Block 1979) que determina la dificultad del mismo.

$$C_f(\%) = 100 \cdot \frac{f_{\max} - f}{f_{\max} - f_{\min}} \quad (7.3)$$

El índice de complejidad expresa la dominancia de flujo de un determinado problema entre la máxima dominancia de flujo, $f_{\max}(n)$ y la mínima $f_{\min}(n)$, estableciendo un valor que permita comparar problemas con distinto número de actividades. En la Figura 7.1.1 se representan los problemas test comentados, con su correspondiente índice de complejidad.

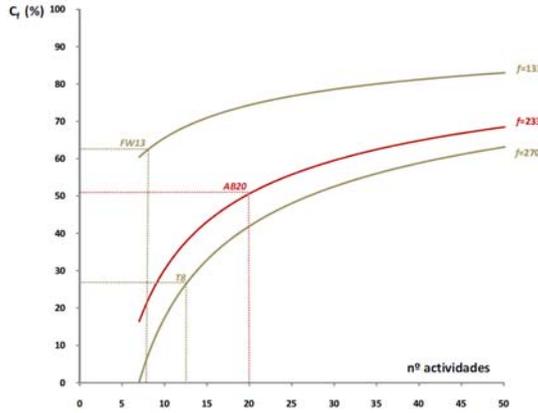


Figura 7.1.1 Índice de complejidad (C_i) de los problemas.

7.2 SOLUCIONES HISTÓRICAS DEL PROBLEMA

En primer lugar y para situar cual es el estado de las aportaciones que se han realizado a la resolución de este problema de test. Se puede realizar una clara distinción de las mismas en función del modelo geométrico que los diferentes autores han empleado en la resolución del problema.

7.2.1 Modelo geométrico discreto

La solución inicial de partida en (Armour y Buffa 1963) es la mostrada en la Figura 7.2.1, con los valores de indicadores empleados en la presente tesis enunciados anteriormente.

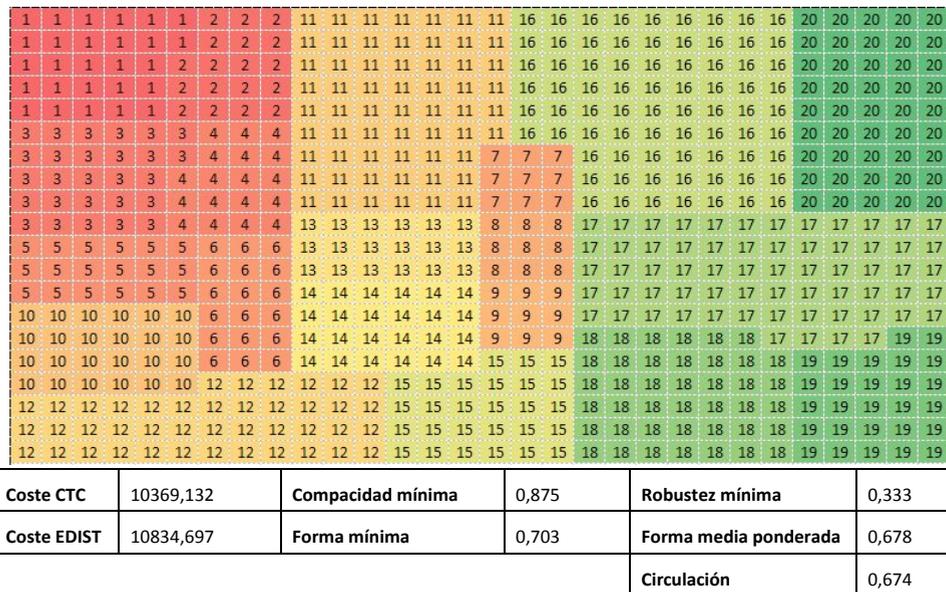
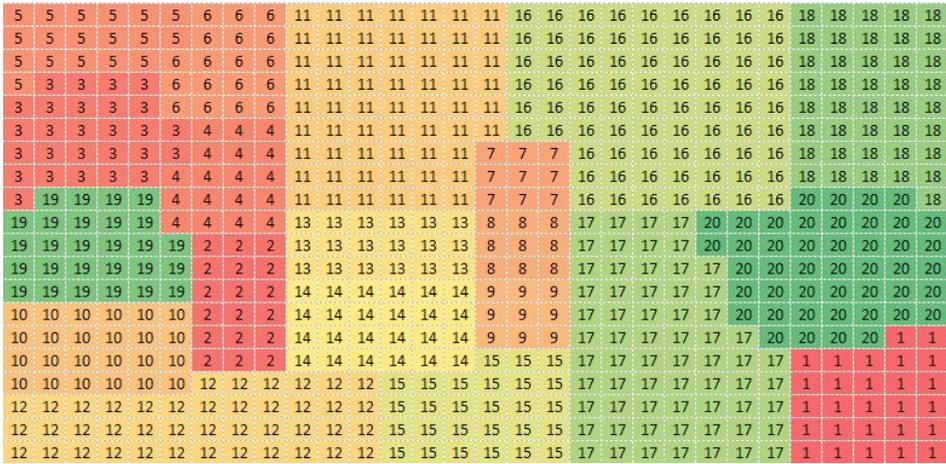


Figura 7.2.1 Solución inicial de (Armour y Buffa 1963), AB00.

Destacar, que la aproximación de Armour y Buffa era una aproximación meramente monobjetivo, con el coste entre centroides como objetivo a minimizar. El resto de indicadores se emplean como valores de referencia para situar las soluciones.

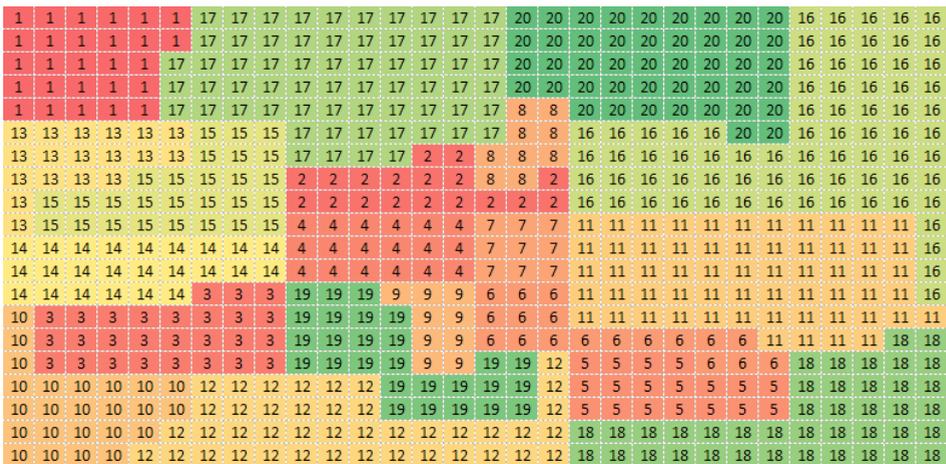
La solución final tras siete iteraciones con el algoritmo CRAFT se muestra en la Figura 7.2.2.



| | | | | | |
|-------------|---------|-------------------|-------|-----------------------|-------|
| Coste CTC | 8085,64 | Compacidad mínima | 0,750 | Robustez mínima | 0,333 |
| Coste EDIST | 8710,53 | Forma mínima | 0,698 | Forma media ponderada | 0,676 |
| | | | | Circulación | 0,632 |

Figura 7.2.2 Solución final de (Armour y Buffa 1963), AB01.

En (Bozer, Meller y Erlebacher 1994) también encontramos una solución al problema AB20, obtenida mediante una aplicación denominada MULTIPLE, concebida para el trabajo con varios pisos, en el que también tienen en cuenta aspectos como la robustez y la compacidad. El espacio también es discreto y el relleno se realiza mediante curvas de relleno (SFC's). La mejor solución obtenida es la mostrada en la Figura 7.2.3.



| | | | | | |
|-------------|---------|-------------------|------|-----------------------|-------|
| Coste CTC | 7064,87 | Compacidad mínima | 0,45 | Robustez mínima | 0,333 |
| Coste EDIST | 7841,75 | Forma mínima | 0,18 | Forma media ponderada | 0,437 |
| | | | | Circulación | 0,55 |

Figura 7.2.3 Solución final de (Bozer, Meller y Erlebacher 1994), BOZ.

Otra aportación a destacar es el mejor resultado obtenido en (Contero Gonzalez 1995) para este problema, con un solo objetivo, pero con un estricto control de la forma de las actividades es el mostrado en la Figura 7.2.4. El autor emplea un algoritmo de construcción tipo CRAFT con una optimización basada en *Simulated Annealing*.

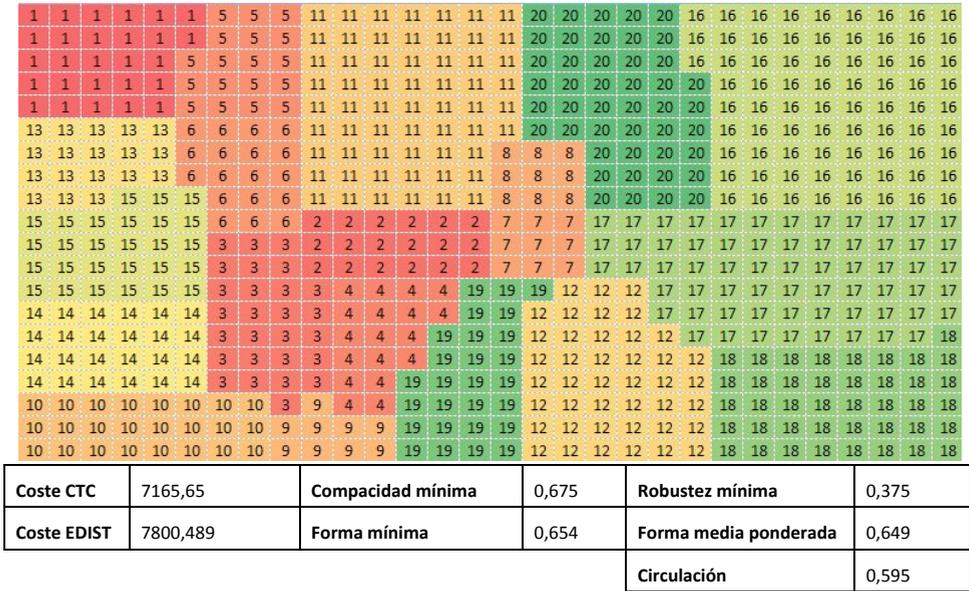
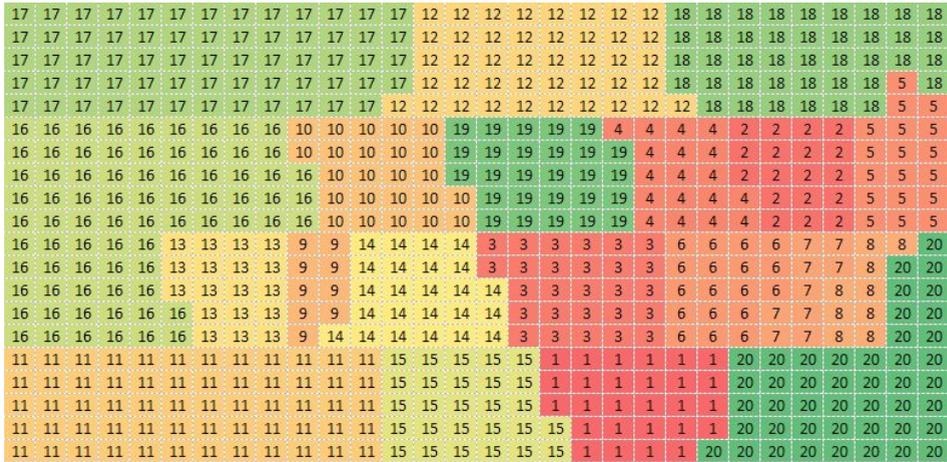


Figura 7.2.4 Mejor resultado obtenido en (Contero Gonzalez 1995), MC.

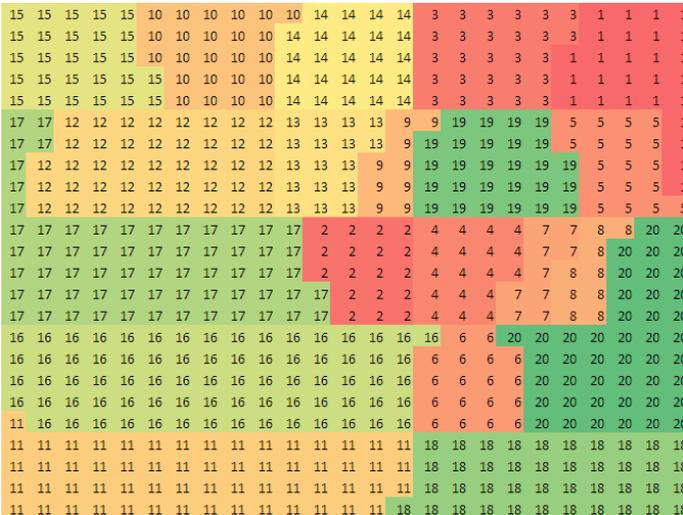
Otras soluciones problema son las dos obtenidas en (Wang, Hu y Ku 2005). Los autores proponen soluciones óptimas (según el criterio de coste entre centroides) para dos recintos de diferente aspecto. En la Figura 7.2.5 se puede encontrar la mejor solución obtenida para el recinto con un $R(a/h)=1.5$ y en la Figura 7.2.6 el mejor resultado obtenido por los autores para un recinto de $R=0.96$.

Los autores abordan el problema con un modelo geométrico discreto, con un mecanismo de relleno oscilatorio de número y ancho de banda constantes. Con esta formulación, el tamaño del espacio de soluciones asociado a esta modelización es de $N_{WANG}=(c+f) \cdot n!$, donde f y c son el número de filas y columnas de la discretización y n es el número de actividades. De este modo $N_{WANG} \approx 10^{20}$. El algoritmo de optimización empleado es un genético.



| | | | | | |
|--------------------|----------|--------------------------|-------|------------------------------|-------|
| Coste CTC | 5927,749 | Compacidad mínima | 0,563 | Robustez mínima | 0,313 |
| Coste EDIST | 6750,653 | Forma mínima | 0,267 | Forma media ponderada | 0,509 |
| | | | | Circulación | 0,535 |

Figura 7.2.5 Solución de (Wang, Hu y Ku 2005) para un recinto R=1.5, MJW1.



| | | | | | |
|--------------------|---------|--------------------------|-------|------------------------------|-------|
| Coste CTC | 5798,05 | Compacidad mínima | 0,533 | Robustez mínima | 0,313 |
| Coste EDIST | 6808,85 | Forma mínima | 0,267 | Forma media ponderada | 0,509 |
| | | | | Circulación | 0,508 |

Figura 7.2.6 Solución de (Wang, Hu y Ku 2005) para un recinto R=0.96, MJW2.

La última aproximación encontrada, con el modelo geométrico discreto se encuentra en (van Camp, Carter y Vanelli 1991), donde se realiza la optimización multiobjetivo del problema de distribución en planta, relacionando coste entre centroides y forma,

compacidad y robustez. El autor emplea un algoritmo MOSA, con el que obtiene soluciones para cada uno de los bicriterios comentados. En la Figura 7.2.7 se adjunta la mejor solución obtenida en el bicriterio Coste-Forma, así como los valores de cada uno de los indicadores de la misma.

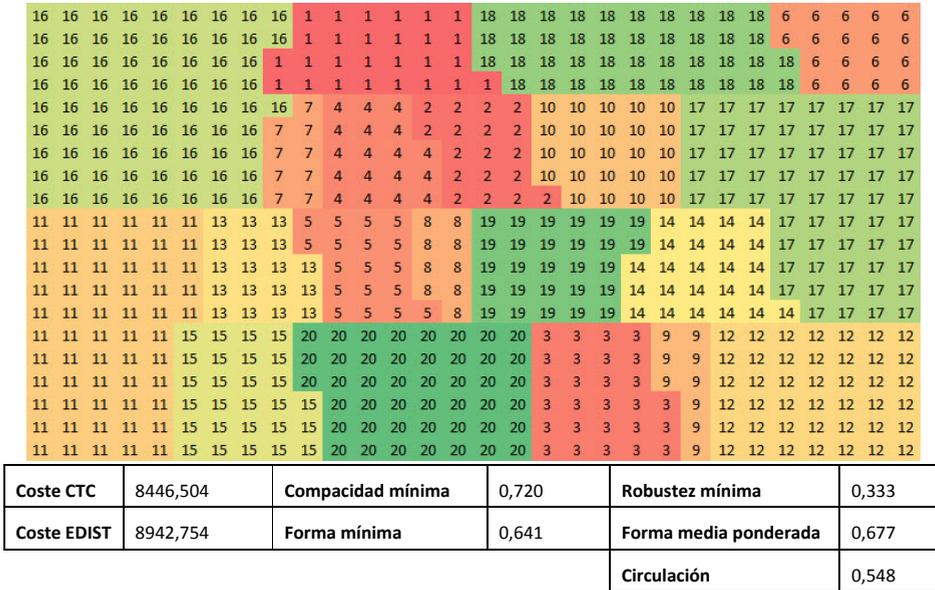


Figura 7.2.7 Solución de (Gonzalez 2005) para el bicriterio Forma-Coste, GON.

7.2.2 Modelo geométrico continuo

Por otra parte, entre los autores que emplean un modelo de geometría continua, también se pueden encontrar soluciones al problema de 20 actividades de Armour y Buffa. En este apartado veremos algunas de las soluciones óptimas que se han encontrado, y las compararemos con las discretas para obtener la frontera de Pareto de partida sobre la que trabajar con la metodología propuesta.

La primera referencia en la que se puede encontrar soluciones al problema es (Tate y Smith 1995), en la que se obtienen distintas soluciones en diferentes lanzamientos del algoritmo, fijando valores mínimos del *aspect ratio* (equivalente a la robustez ρ). Estas soluciones se emplean en multitud de referencias posteriores como soluciones de partida. Las configuraciones de los resultados de Tate y Smith, así como los valores de los indicadores estudiados en el presente trabajo se adjuntan en las siguientes figuras y tablas.

El modelo geométrico empleado es un modelo continuo de tipo *flexbay*. En este caso el tamaño del espacio de soluciones puede estimarse como $N = \frac{1}{6} \cdot (n^3 - n)n!$, para el problema de tamaño $n=20$, el tamaño aproximado es de $N_{Tate} \approx 10^{21.5}$.

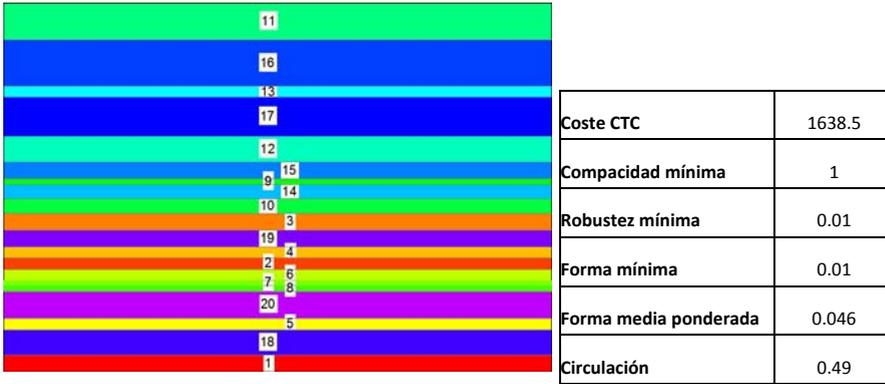


Figura 7.2.8 Solución TS1 de (Tate y Smith 1995) y valores de indicadores.

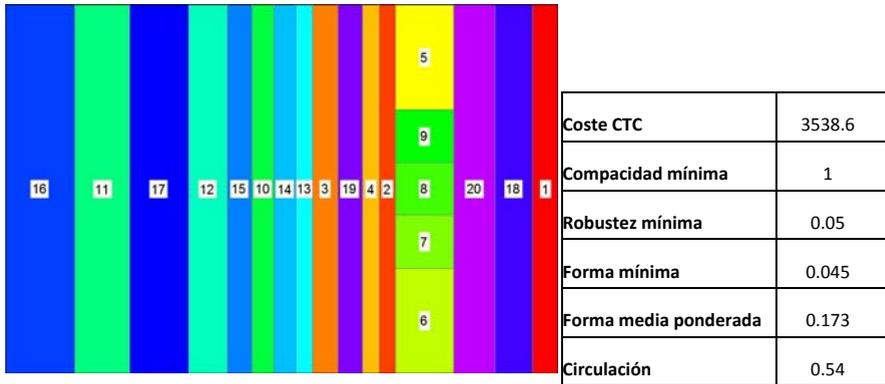


Figura 7.2.9 Solución TS2 de (Tate y Smith 1995) y valores de indicadores.

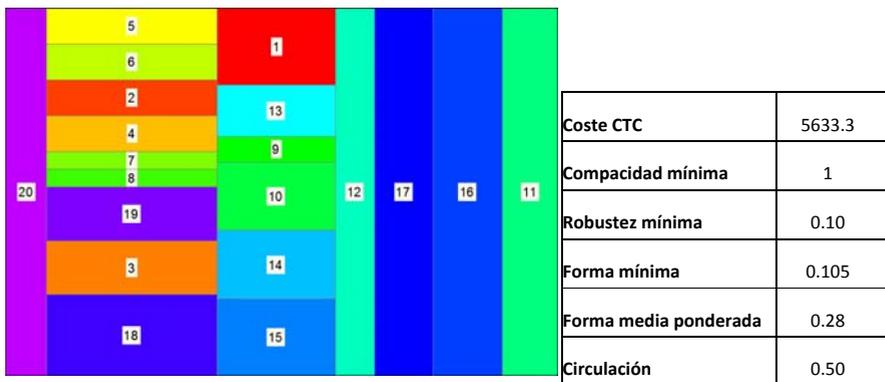


Figura 7.2.10 Solución TS3 de (Tate y Smith 1995) y valores de indicadores.

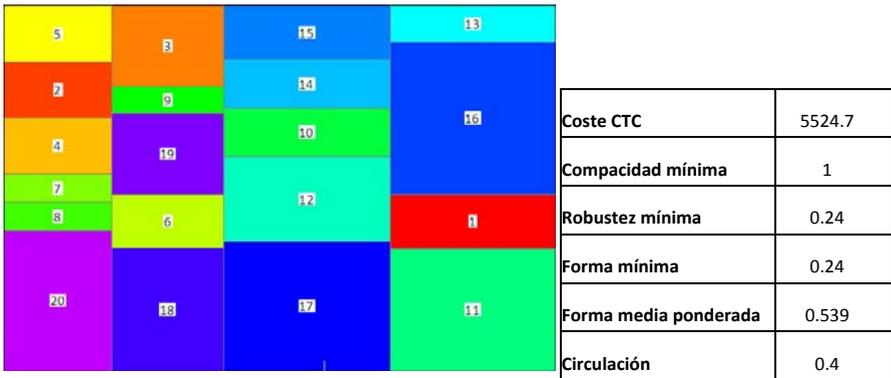


Figura 7.2.11 Solución TS4 de (Tate y Smith 1995) y valores de indicadores.

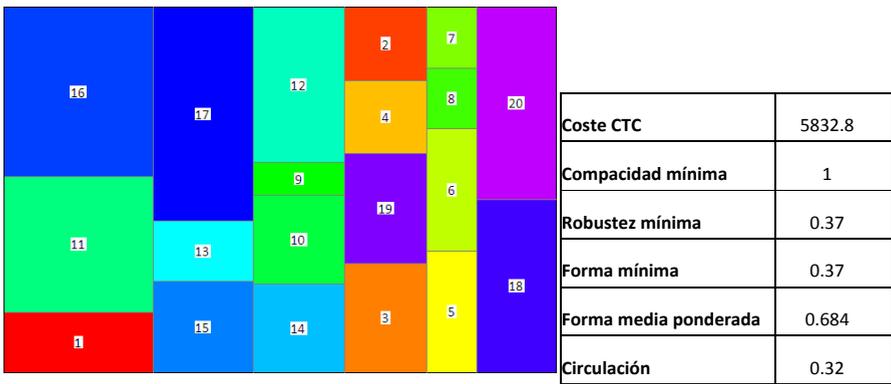


Figura 7.2.12 Solución TS5 de (Tate y Smith 1995) y valores de indicadores.

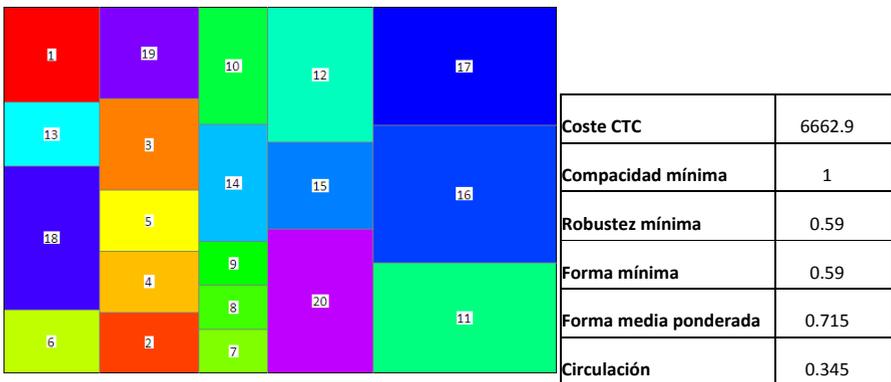


Figura 7.2.13 Solución TS6 de (Tate y Smith 1995) y valores de indicadores.

En (Meller y Gau 1996) se encuentra otra solución al problema AB20, construida sobre una geometría continua y un modelo basado en arboles de corte, y optimizada atendiendo a dos criterios, coste y adyacencia. La mejor solución propuesta es la mostrada en la Figura 7.2.14. El tamaño del espacio de configuraciones que puede representar un modelo geométrico basado en árboles de corte puede expresarse como:

$$N = p^{n-1} \prod_{i=0}^{n-2} C_{n-i}^2 = \left(\frac{p}{2}\right)^{n-1} n!(n-1)!$$

Donde: p es la cardinalidad del conjunto de operadores y n es el número de actividades.

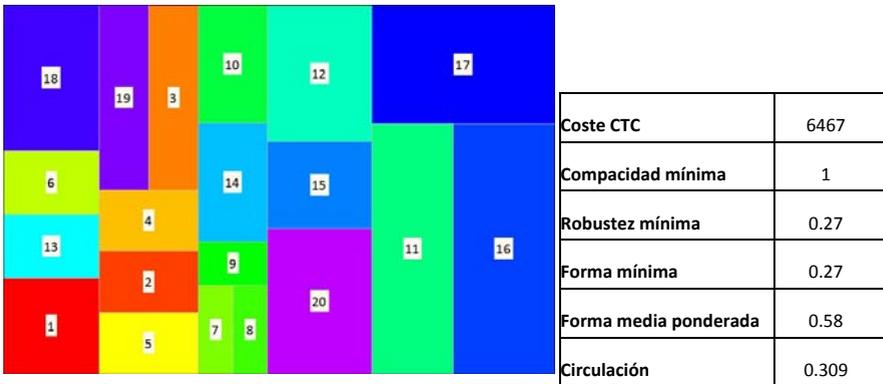


Figura 7.2.14 Solución MEL de (Meller y Gau 1996) y valores de indicadores.

Otro trabajo que empleando una geometría continua ha utilizado el problema de Armour&Buffa de 20 actividades para ilustrar la eficacia de su propuesta, se puede encontrar en (Kim y Kim 1998). El modelo geométrico de Kim es continuo y basado en cortes guiados por la matriz de localización. El tamaño del espacio de soluciones de este modelo geométrico es de $N = (f \cdot c)! / (f - c - n)!$, siendo f y c el número de filas y columnas de la matriz de localización y n el número de actividades del problema. En este caso en concreto, para 20 actividades, se tiene que $N_{KIM} = 35! / (35 - 20)! \approx 10^{28}$.

Las tres soluciones finales del problema AB20 obtenidas por Kim (e identificadas como K1, K2 y K3) se presentan en las Figura 7.2.15 a Figura 7.2.17 junto con los valores de los indicadores de calidad geométrica y coste de que se utilizan en la formulación multiobjetivo de la metodología propuesta.

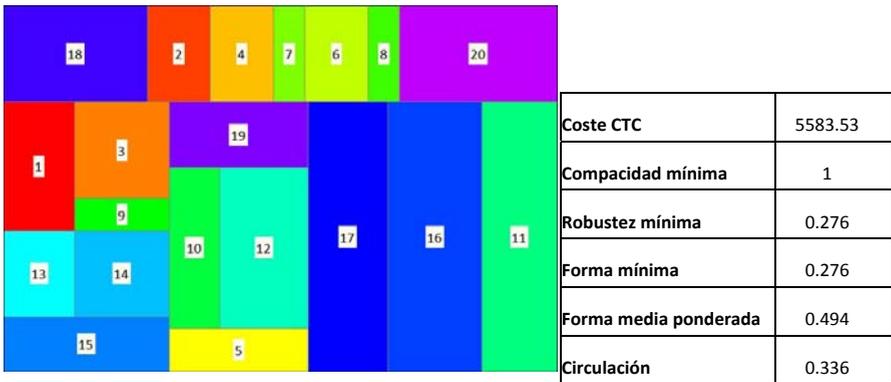


Figura 7.2.15 Solución K1 de (Kim y Kim 1998) y valores de indicadores.

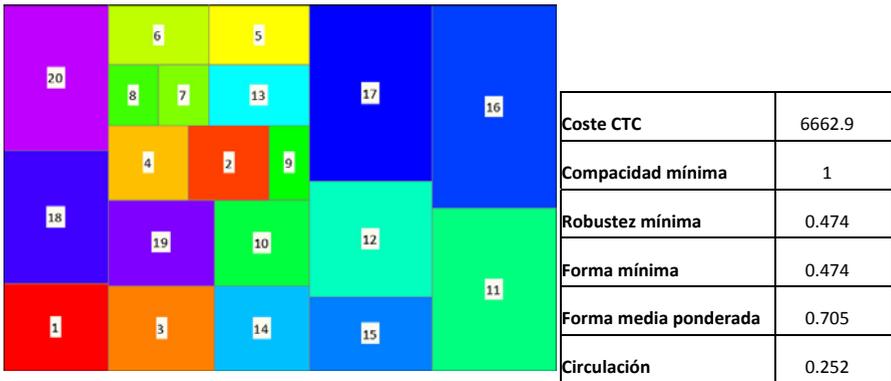


Figura 7.2.16 Solución K2 de (Kim y Kim 1998) y valores de indicadores.

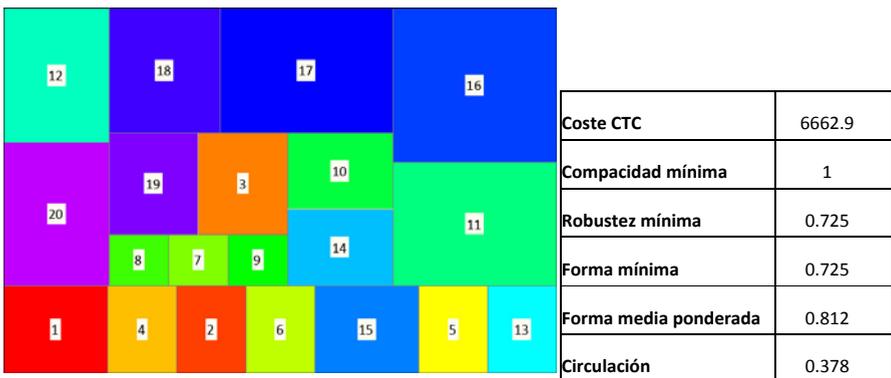


Figura 7.2.17 Solución K3 de (Kim y Kim 1998) y valores de indicadores.

Otro autor que emplea el problema de Armour y Buffa de 20 actividades para probar su algoritmo, basado en *Scatter Diagram* es (Anjos y Vanelli 2006). La solución de coste óptimo para un valor de robustez admisible es la mostrada en la Figura 7.2.18.

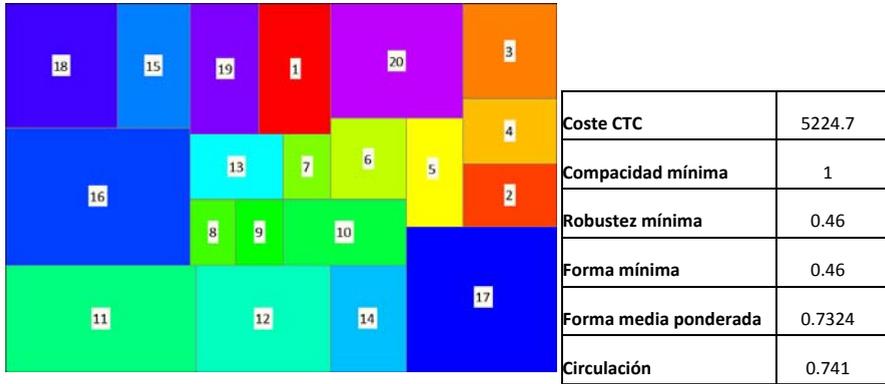


Figura 7.2.18 Solución ANJ de (Anjos y Vanelli 2006) y valores de indicadores.

7.2.3 Fronteras de Pareto bicriterio del problema

Si se plasman todas las soluciones anteriormente citadas en gráficos bicriterio, se pueden obtener las fronteras de Pareto "históricas" para el problema de Armour y Buffa de 20 actividades atendiendo a los principales criterios de configuración e individuales.

En las siguientes figuras se pueden observar las posiciones de todas las soluciones históricas obtenidas, ordenadas según los diferentes objetivos. Con círculos se tienen las soluciones en las que se emplea un marco geométrico continuo y con triángulos las soluciones obtenidas sobre marcos discretos. El coste evaluado en todos los casos es el denominado coste entre centroides (CTC).

7.2.3.1 Indicadores de configuración

Los indicadores empleados en el presente trabajo que consideran la configuración global de la solución son la Circulación, Forma Media Ponderada y el indicador SRF de Wang.

La frontera de Pareto del bicriterio Coste-Circulación (indicador propuesto en la presente investigación) está compuesta por 4 puntos, todos ellos correspondientes a autores que emplean un modelo geométrico continuo. Si se consideran únicamente los discretos, la frontera de Pareto está conformada por un único punto, el correspondiente a la segunda solución de (Wang, Hu y Ku 2005), que consideraba un recinto cuadrado.

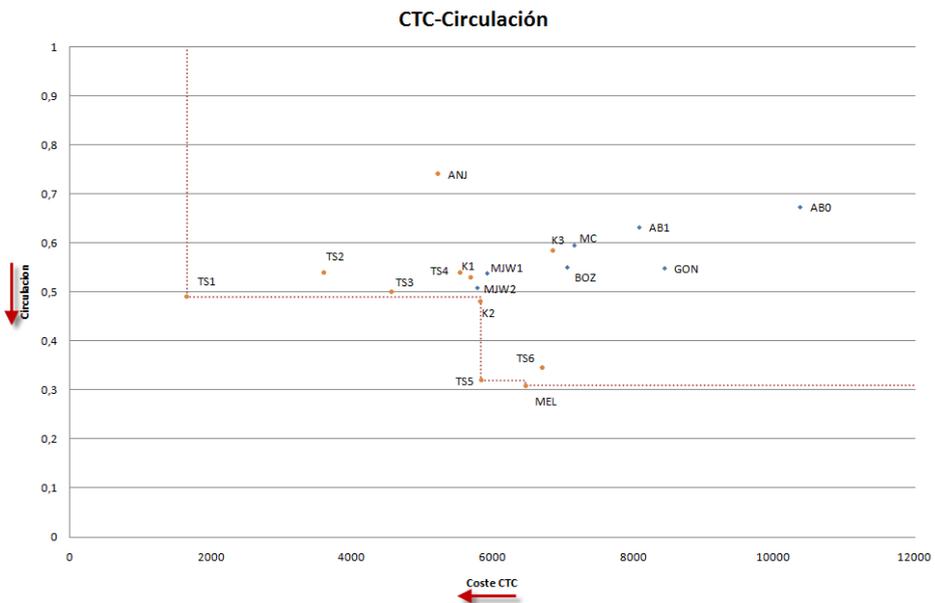


Figura 7.2.19 Frontera de Pareto "histórica" para los criterios coste-circulación.

En cuanto al indicador de forma media ponderada, la frontera de Pareto obtenida con todas las soluciones históricas está compuesta por seis puntos, todos ellos obtenidos mediante un modelo geométrico continuo. La frontera considerando únicamente a los autores que emplean un modelo discreto estaría compuesta por 4 puntos.

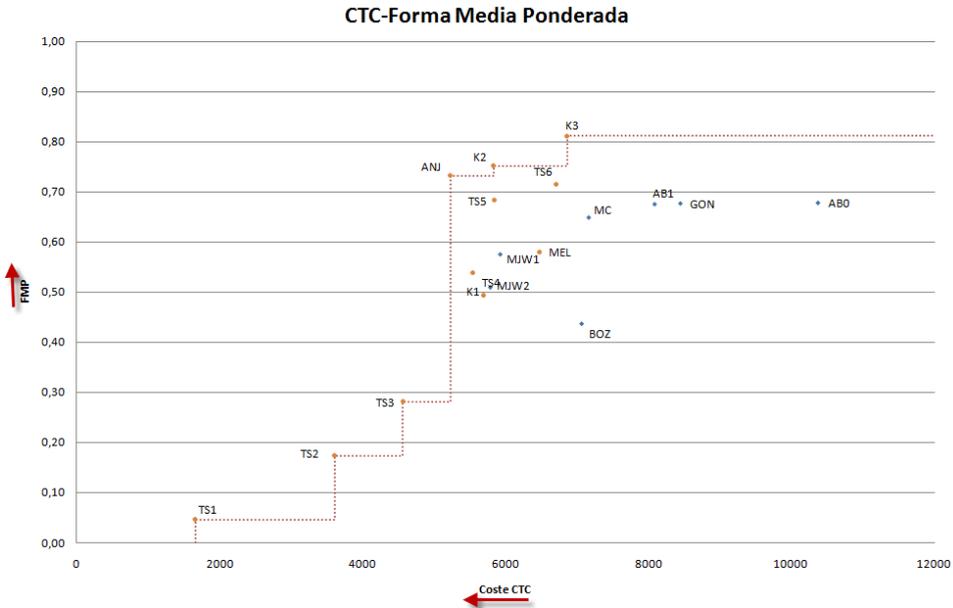


Figura 7.2.20 Frontera de Pareto "histórica" para los criterios coste-forma media ponderada.

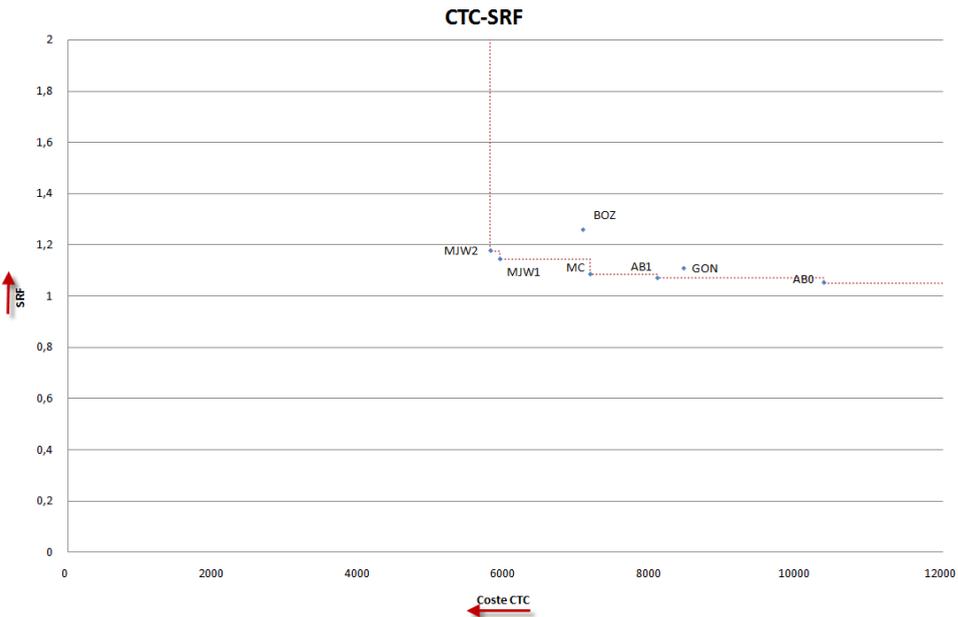


Figura 7.2.21 Frontera de Pareto "histórica" para los criterios coste-SRF.

Por último se considera el indicador SRF, que tal y como se comentó con anterioridad es un indicador únicamente representativo en el caso de modelos geométricos discretos, la frontera de Pareto está conformada por cinco puntos, correspondientes a las soluciones proporcionadas por (Wang, Hu y Ku 2005), (Contero Gonzalez 1995) y las dos originales de (Armour y Buffa 1963)

7.2.3.2 Indicadores de actividad

En el presente trabajo, tal y como se concluyó en capítulos anteriores, se emplean otros indicadores de actividad, que consideran el peor de los valores del conjunto de las 20 actividades del problema a la hora de obtener el global, como son la Forma, la Robustez y la Compacidad.

En el caso de la forma mínima, la frontera de Pareto histórica queda definida por nueve puntos, dos de los cuales corresponden a las soluciones de (Wang, Hu y Ku 2005) obtenidas mediante un modelo discreto y el resto son obtenidas mediante modelos continuos.

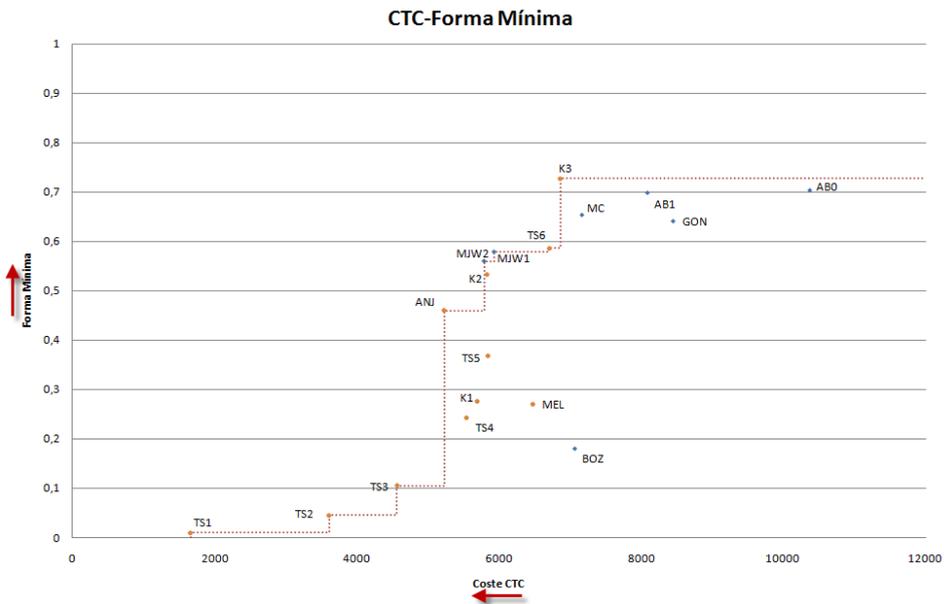


Figura 7.2.22 Frontera de Pareto "histórica" para los criterios coste-forma mínima.

La frontera de Pareto histórica para el bicriterio coste-robustez está compuesta por siete puntos, todos ellos obtenidos con modelos geométricos continuos.

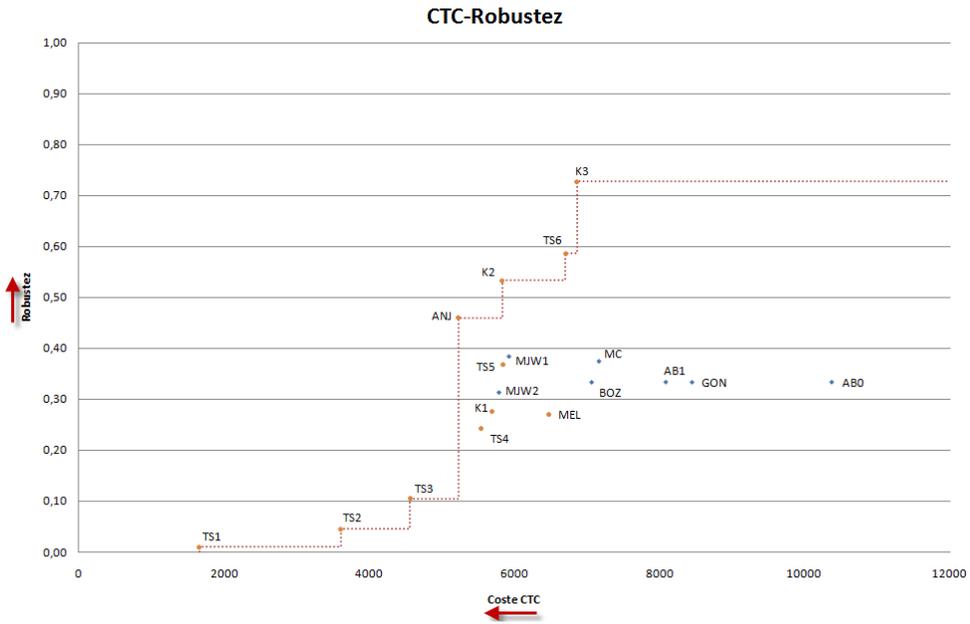


Figura 7.2.23 Frontera de Pareto "histórica" para los criterios coste-robustez mínima.

Por último se adjunta la frontera relativa a los indicadores coste-compacidad de las soluciones históricas de los autores que emplean un modelo con geometría discreta, pues en aquellos en los que se emplea geometría continua siempre alcanzan, por el mismo, el valor máximo de compacidad en todas sus actividades (compacidad=1).

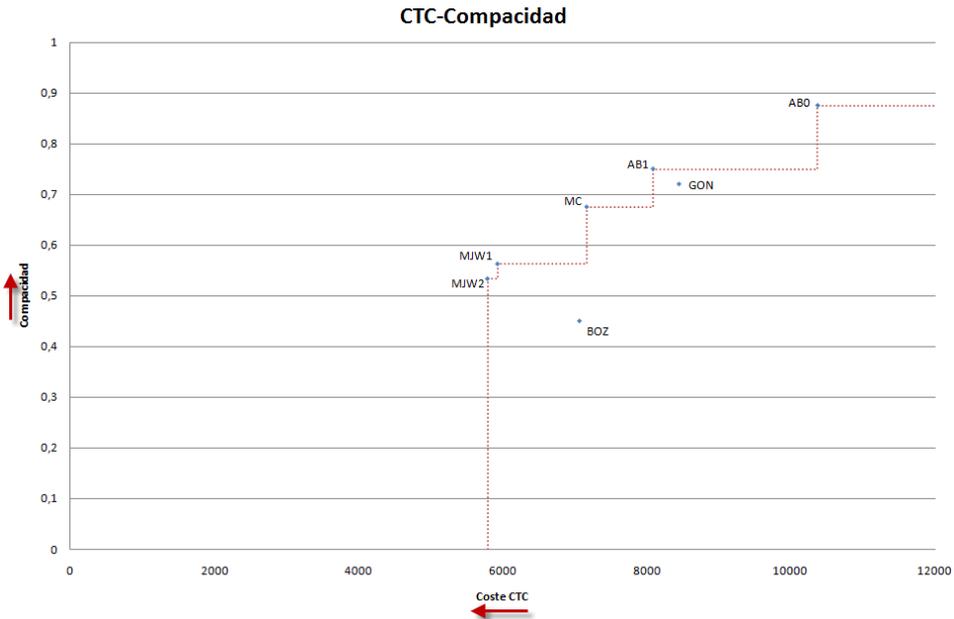


Figura 7.2.24 Frontera de Pareto "histórica" para los criterios coste-compacidad.

7.2.4 Frontera de Pareto Coste - Circulación - Forma Media Ponderada

La representación de las soluciones históricas del problema atendiendo a los tres criterios de configuración (Coste, Circulación y FMP) es la mostrada en el gráfico 3D de la Figura 7.2.25. El punto marcado en rojo es la que se denomina *Utopía de Pareto*, punto que dominaría a todas las soluciones conocidas del problema, pues conjuga los valores mínimos de los tres objetivos, en este caso, el coste de la solución TS1 (1653.49), la circulación de la solución MEL (0.31) y la forma media ponderada de la solución K3 (0.81). Destacar que las tres soluciones que conforman esta utopía son construidas sobre un modelo geométrico continuo.

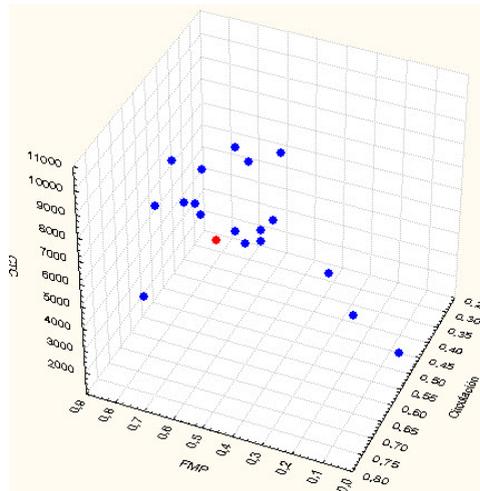


Figura 7.2.25 Valores "históricos" de los indicadores Coste, Circulación y FMP.

7.3 EVALUACIÓN DEL POTENCIAL DEL MODELO GEOMÉTRICO EMPLEADO

Tal y como se comentó en la ecuación (7.1), el problema AB20, sobre un modelo geométrico discreto, como el empleado en el presente trabajo, tiene un tamaño del espacio de soluciones del orden de 10^{715} . Para tener alguna noción de la bondad del generador de soluciones empleado en la investigación, se realizó un paseo aleatorio (generando 50.000 soluciones) para determinar la calidad de las soluciones “no guiadas” obtenidas con el mismo.

Durante el paseo no se empleó ningún tipo de restricciones en cuanto al orden de las actividades, así como en el número y dimensiones de las bandas generadas para permitir que la generación fuera lo más aleatoria posible.

En las siguientes figuras se representan los resultados obtenidos haciendo referencia a los distintos criterios empleados (tanto de configuración como de actividad) y mostrando su posición en relación a la frontera de Pareto histórica obtenida anteriormente.

Como se observará en los siguientes apartados, las soluciones obtenidas en el paseo aleatorio en todos los casos, están lejos de la frontera de Pareto histórica y mediante la técnica de optimización se guiarán hacia soluciones cercanas a la frontera, introduciendo, en algunos casos nuevos puntos en la misma.

En la Figura 7.4.2 se puede observar el resultado obtenido tras el proceso de optimización, con la nueva frontera presentada para este indicador. Los puntos encontrados se sitúan en valores de coste del orden de 5000 unidades, que están muy alejados de los resultados obtenidos en el paseo aleatorio.

Tal y como se observa en la siguiente figura, los valores obtenidos para el indicador de Forma Media Ponderada están muy lejos de la frontera histórica, compuesta por aproximaciones con un modelo geométrico continuo y también de las soluciones encontradas con un modelo discreto.

En la Figura 7.4.9 se pueden observar las soluciones obtenidas para este bicriterio tras la fase de optimización, que alcanzan a alguna de las mejores soluciones con modelo geométrico discreto e incluso introducen algún punto en la frontera de Pareto global.

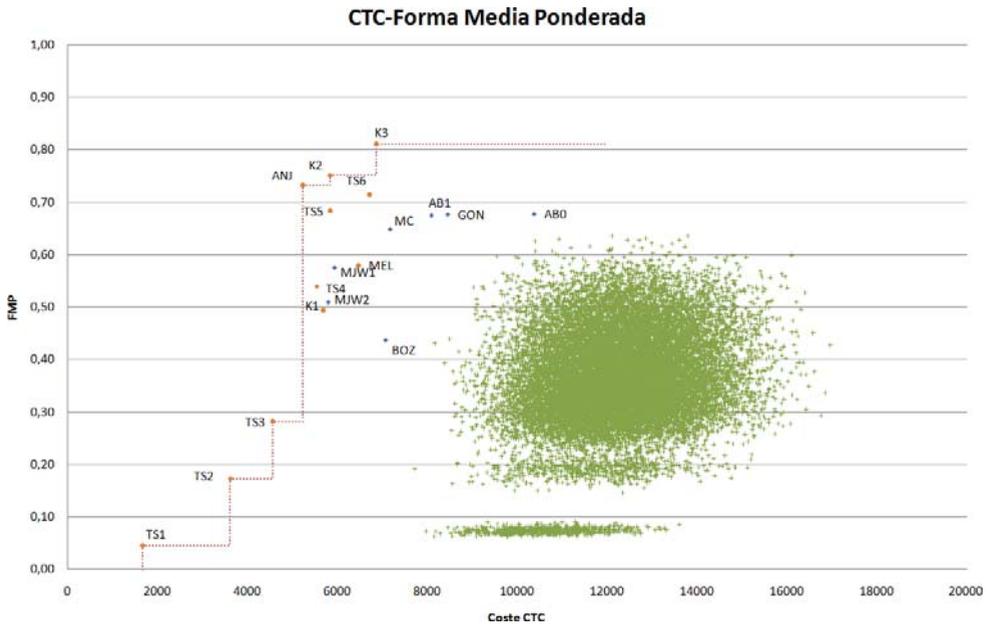


Figura 7.3.2 Resultados de paseo aleatorio para el bicriterio Coste - FMP.

Finalmente se muestran los resultados obtenidos para el criterio SRF y su relación con los valores encontrados en las referencias de aquellos autores que emplean modelos geométricos discretos, pues este indicador es únicamente vigente para estos casos. En la Figura 7.4.13 se muestran los resultados obtenidos tras el proceso de optimización.

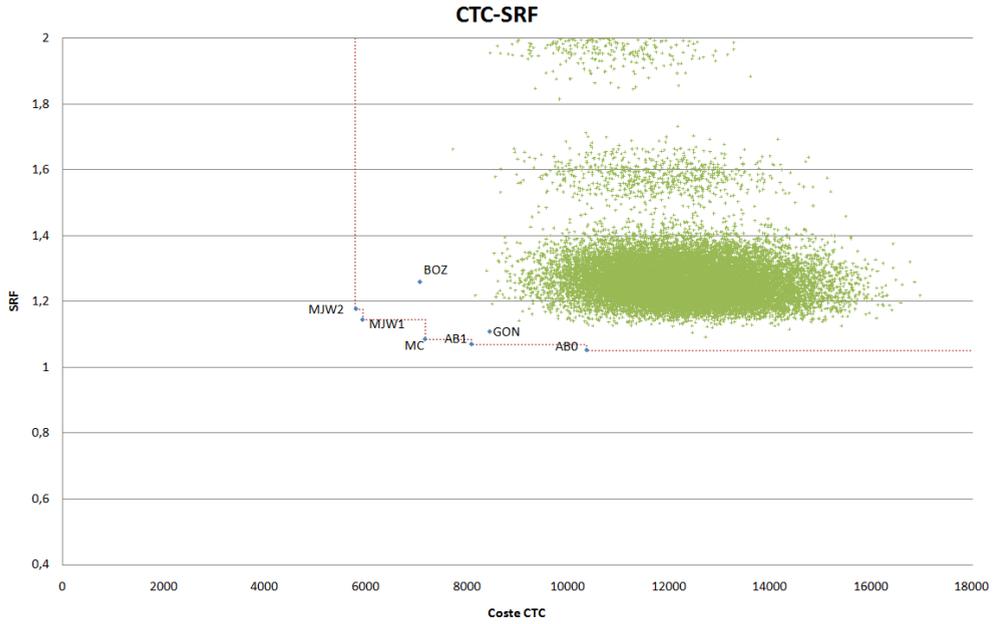


Figura 7.3.3 Resultados de paseo aleatorio para el bicriterio Coste - SRF.

7.3.2 Indicadores de actividad

En las siguientes figuras se muestran los resultados obtenidos en el paseo aleatorio para los indicadores de actividad. En este punto cabe recordar que los valores obtenidos se corresponden con el peor de los valores de las 20 actividades de las que se compone el problema.

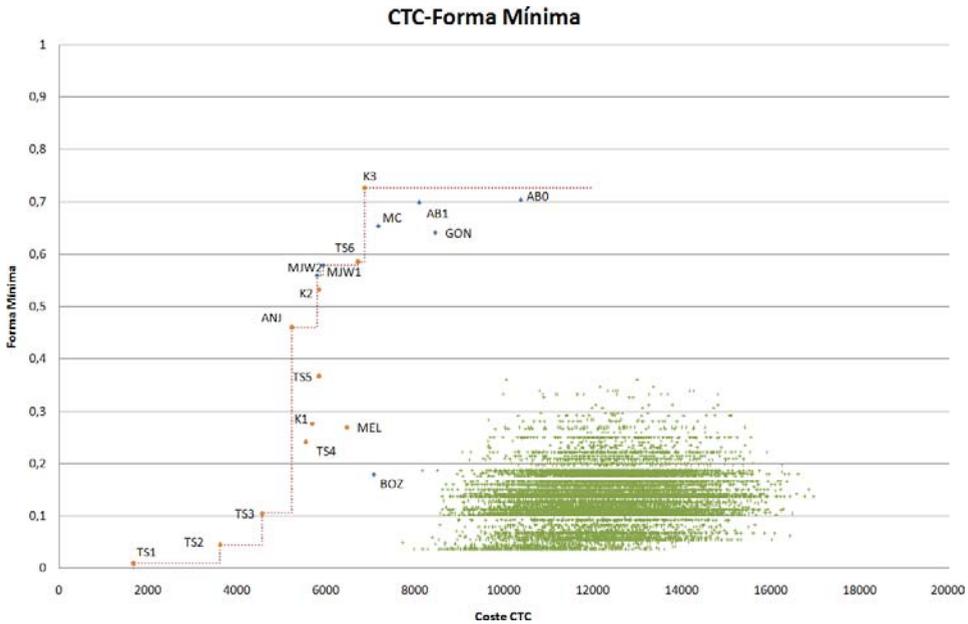


Figura 7.3.4 Resultados de paseo aleatorio para el bicriterio Coste - Forma mínima.

La primera figura se corresponde con el criterio de forma de una actividad, en este caso, el indicador es la menor forma de todas las actividades del problema, pudiéndose observar que el constructor de soluciones tiene a generar configuraciones con valores de forma muy alejados de los mejores obtenidos en la bibliografía.

En segundo lugar, en la Figura 7.3.5, se muestran los resultados obtenidos para el indicador de robustez, y su relación con los valores de la frontera histórica. Los valores del paseo aleatorio se distribuyen de una forma similar a los valores de Forma, estando igualmente alejados de la frontera. Tras el proceso de optimización, se obtienen valores muy cercanos a la misma, incluso introduciendo nuevos puntos a la frontera, tal y como se puede observar en la Figura 7.4.24.

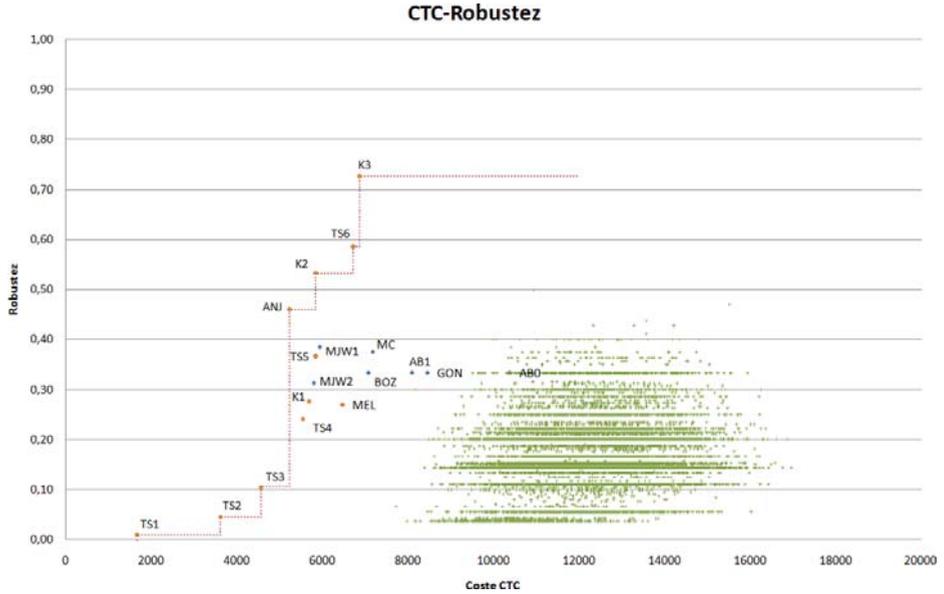


Figura 7.3.5 Resultados de paseo aleatorio para el bicriterio Coste - Robustez.

Finalmente, en la Figura 7.3.6 se muestran los resultados del indicador de compacidad, y su posición relativa con la frontera de Pareto de este bicriterio. Destacar, que tal y como se comentó en la definición del indicador, es únicamente valido para modelos geométricos discretos. Las soluciones obtenidas están lejos de la frontera, y tras la optimización realizada se obtienen puntos que mejoran todos los de la frontera histórica de este bicriterio, como se puede ver en la Figura 7.4.27.

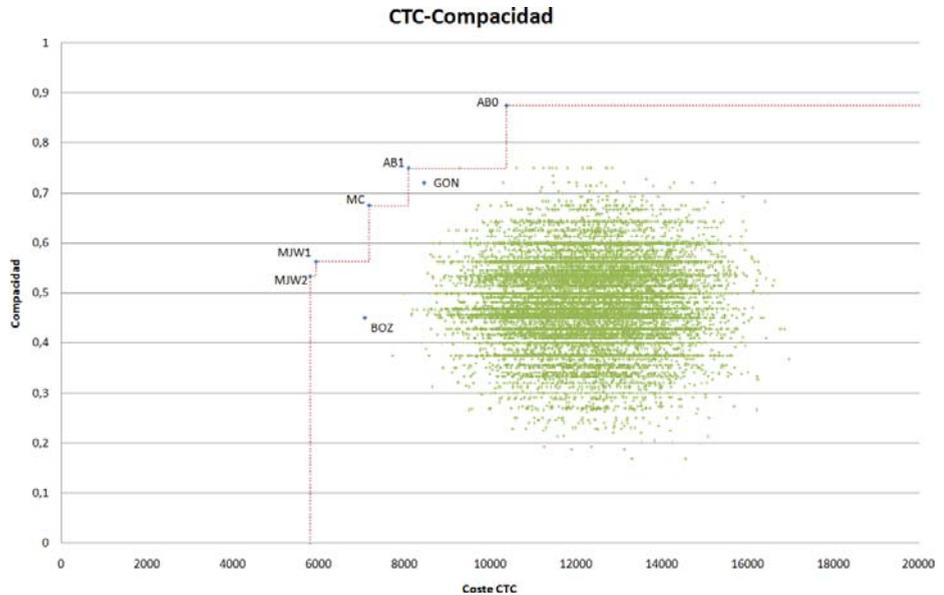


Figura 7.3.6 Resultados de paseo aleatorio para el bicriterio Coste - Compacidad.

7.4 PLAN EXPERIMENTAL Y SOLUCIONES OBTENIDAS

Una vez se ha comentado todo lo relativo a la metodología que se ha empleado en la presente investigación solo resta comentar el plan experimental que se siguió, así como los resultados obtenidos en el mismo.

Con este plan experimental se persiguen tres objetivos fundamentales:

1. Conseguir una mejora en las fronteras de Pareto bicriterio de los indicadores de configuración y actividad encontrados en las referencias bibliográficas del problema de Armour y Buffa de 20 actividades.
2. Realizar la primera optimización con el indicador de circulación propuesto en el presente trabajo.
3. Abordar, por primera vez, el problema con tres objetivos independientes.

Para ello se emplea una estrategia de experimentos independientes, tal y como se comentó en el apartado 6.4 en los que se irá conformando la frontera de Pareto para cada uno de los bicriterios, así como la frontera para el problema con 3 objetivos.

El número de lanzamientos independientes varía en función de la frontera conseguida en cada paso y se comentará específicamente en cada punto. A continuación se muestran los resultados obtenidos para los siguientes casos:

- Fronteras bicriterio:
 - Configuración: CTC-Circulación, CTC-Forma Media Ponderada, CRC-SRF.
 - Actividad: CTC-Forma, CTC-Robustez, CTC-Compacidad.
- Frontera tricriterio: CTC-FMP-Circulación.

7.4.1 Obtención de Fronteras de Pareto Bicriterio

7.4.1.1 Frontera Coste-Circulación

Uno de los objetivos fundamentales del presente trabajo es optimizar y encontrar nuevos puntos para la frontera de Pareto del bicriterio coste entre centroides y el nuevo indicador propuesto, la circulación.

Tal y como se comentó con anterioridad, y puede verse en la Figura 7.2.19, la frontera de Pareto para estos dos objetivos, obtenida mediante el conjunto de soluciones históricas (tanto discretas como continuas), está formado por 4 soluciones (todas ellas continuas), siendo por tanto, una frontera muy poco definida.

Se realizaron 41 lanzamientos independientes del algoritmo, deteniéndose los lanzamientos al detectar que se habían producido 5 consecutivos sin obtener una mejora en la frontera de Pareto. La evolución de la misma se puede observar en la Figura 7.4.1, así como la posición de la frontera final (en rojo) respecto a las soluciones históricas del bicriterio obtenidas con modelos geométricos discretos. Destacar, que desde las primeras fronteras generadas, se dominan todas las soluciones que emplean un modelo geométrico discreto.

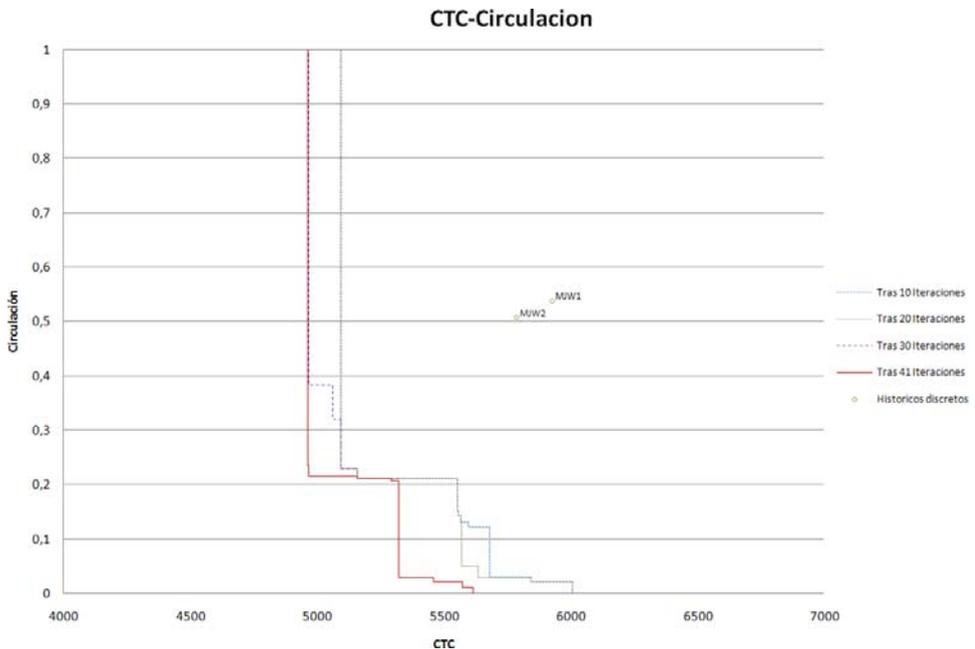


Figura 7.4.1 Evolución de la frontera CTC-Circulación.

En la Figura 7.4.2 se muestra la frontera final obtenida en el proceso así como todos los puntos que en algún momento del proceso han formado parte de la misma, y que posteriormente han sido dominados por nuevos puntos de la frontera, y la posición de las soluciones históricas discretas respecto a la frontera.

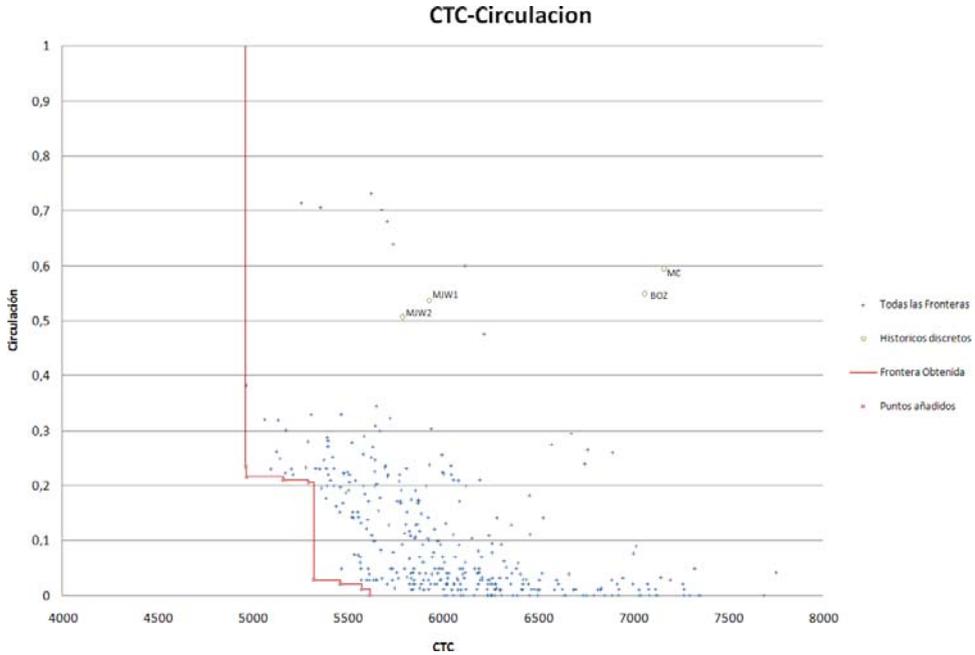


Figura 7.4.2 Frontera de Pareto discreta del bicriterio Coste-Circulación.

En la Figura 7.4.3 se presenta la frontera de Pareto obtenida para el bicriterio Coste-Circulación, en la que se introducen 8 nuevos puntos, con valores de circulación muy bajos (incluso alcanzándose valores iguales a 0), que dominan a tres de las soluciones que conformaban la frontera de Pareto histórica, quedando únicamente en la frontera final dos puntos de los continuos que tienen valores de coste muy bajos debido a la laminación de las actividades, como se comentó anteriormente.

También se incluye la utopía de Pareto para este bicriterio, compuesto por el coste de la solución TS1 y el valor nulo de la circulación.

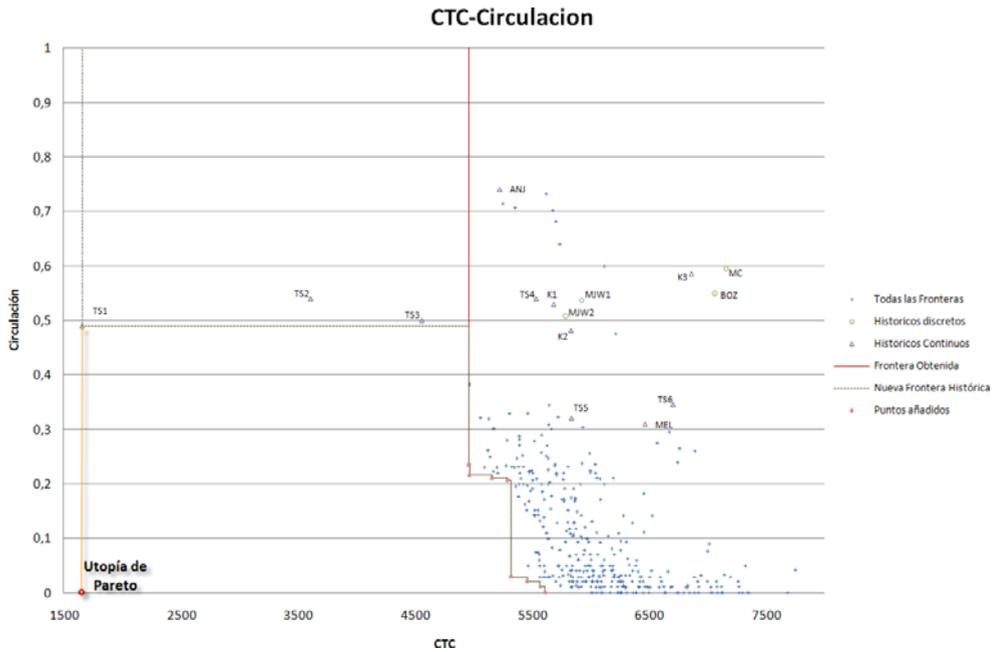


Figura 7.4.3 Nueva frontera de Pareto del bicriterio Coste-Circulación.

Los puntos introducidos en la frontera son los mostrados en la siguiente tabla:

| Nº Sol | Código Solución | Coste | Circulación |
|--------|---|---------|-------------|
| 1 | 1-18-11-16-17-13-15-10-12-5-14-9-3-8-19-2-4-7-20-6 7 2+2+2+2+2+18 | 5616,67 | 0 |
| 2 | 1-18-11-16-5-17-15-10-12-13-14-9-3-8-19-2-4-7-20-6 7 2+2+2+2+2+18 | 5573,67 | 0,011 |
| 3 | 1-18-11-16-13-17-15-10-12-5-14-9-3-8-19-2-4-7-20-6 7 2+2+2+2+2+18 | 5462,34 | 0,021 |
| 4 | 1-11-16-15-17-18-13-14-5-9-10-12-3-8-19-2-4-7-20-6 7 2+2+2+2+2+18 | 5323,50 | 0,029 |
| 5 | 16-11-18-13-12-10-1-9-14-15-17-3-19-2-4-20-8-5-7-6 6 2+2+2+2+2+20 | 5293,93 | 0,206 |
| 6 | 13-18-11-16-1-2-4-5-6-19-7-3-8-20-10-9-14-15-17-12 6 2+2+2+3+2+19 | 5162,54 | 0,210 |
| 7 | 16-11-18-13-15-17-12-9-10-14-1-3-19-2-4-20-8-5-7-6 6 2+2+2+2+2+20 | 4968,81 | 0,216 |
| 8 | 16-11-18-13-1-17-12-9-10-14-15-3-19-2-4-20-8-5-7-6 6 2+2+2+2+2+20 | 4964,38 | 0,235 |

Tabla 7.4.1 Soluciones aportadas a la frontera de Pareto Coste-Circulación

7.4.1.2 Frontera Coste-Forma Media Ponderada

Otro de los indicadores objeto de estudio es la forma media ponderada (FMP), cuya frontera obtenida con las soluciones históricas, que se muestra en la Figura 7.2.20 tiene 6 soluciones.

Se realizaron 61 lanzamientos independientes del algoritmo, deteniéndose el experimento al detectar 5 consecutivos sin que se produjera mejora alguna en la frontera obtenida. La evolución de la misma es la mostrada en la Figura 7.4.6, siendo la frontera final obtenida la grafiada en color rojo que domina a todas las soluciones discretas salvo a las dos propuestas por (Wang, Hu y Ku 2005).

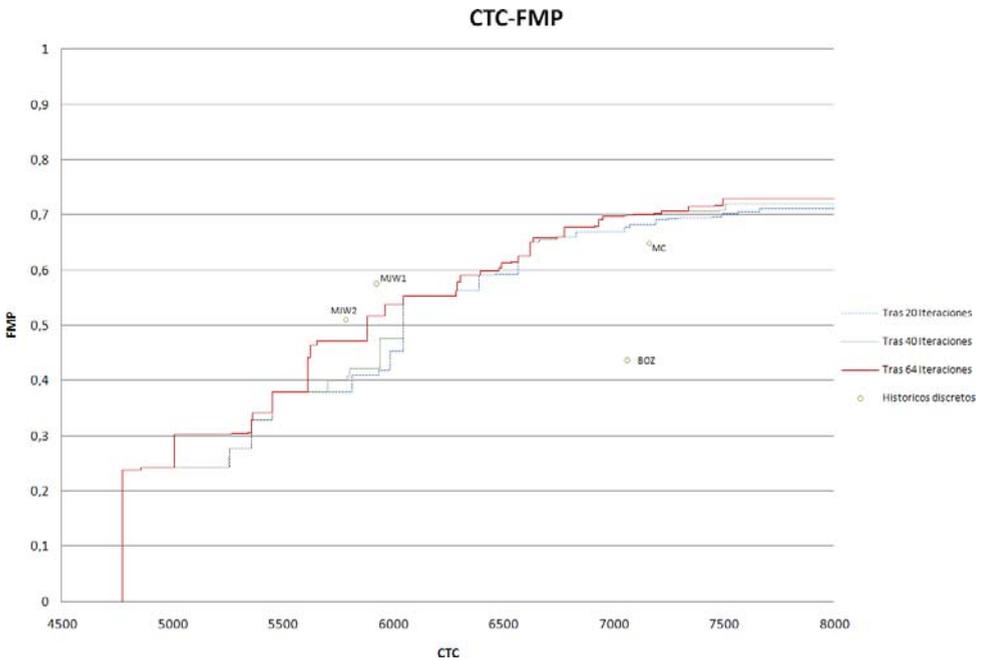


Figura 7.4.6 Evolución de la frontera de Pareto Coste-FMP.

La frontera obtenida considerando las dos soluciones discretas comentadas anteriormente se muestra en la Figura 7.4.7 (compuesta por 42 soluciones).

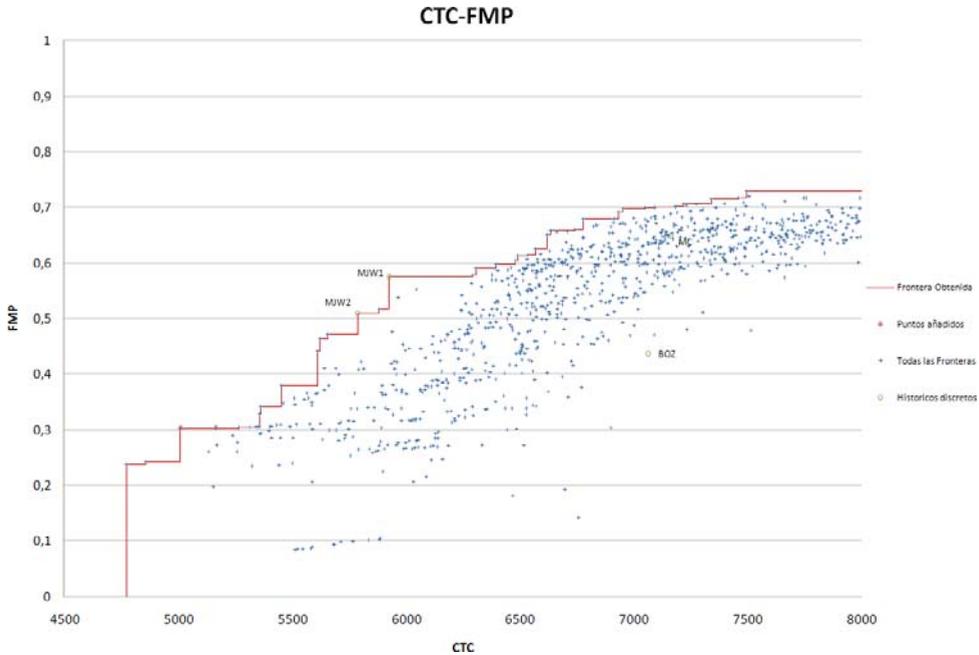


Figura 7.4.7 Frontera de Pareto Coste-FMP obtenida.

En la Figura 7.4.8 se muestra una solución con un valor elevado de la forma media ponderada (0.729) y un valor de coste también elevado (7497.48). La forma global de la solución es correcta, aunque el coste sea algo más elevado que en el resto de soluciones de la frontera.

| | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|
| 6 | 6 | 6 | 19 | 19 | 19 | 19 | 19 | 3 | 3 | 3 | 3 | 15 | 15 | 15 | 15 | 15 | 15 | 5 | 5 | 5 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | | |
| 6 | 6 | 6 | 19 | 19 | 19 | 19 | 19 | 3 | 3 | 3 | 3 | 15 | 15 | 15 | 15 | 15 | 15 | 5 | 5 | 5 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | | |
| 6 | 6 | 6 | 19 | 19 | 19 | 19 | 19 | 3 | 3 | 3 | 3 | 3 | 3 | 15 | 15 | 15 | 15 | 5 | 5 | 5 | 5 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | | |
| 6 | 6 | 6 | 19 | 19 | 19 | 4 | 4 | 3 | 3 | 3 | 3 | 3 | 3 | 15 | 15 | 15 | 15 | 5 | 5 | 5 | 5 | 1 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | | |
| 6 | 6 | 6 | 19 | 19 | 19 | 4 | 4 | 3 | 3 | 3 | 3 | 3 | 3 | 15 | 15 | 15 | 15 | 5 | 5 | 5 | 5 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | | |
| 6 | 6 | 6 | 19 | 19 | 19 | 4 | 4 | 18 | 18 | 18 | 18 | 18 | 3 | 15 | 15 | 15 | 9 | 14 | 14 | 14 | 14 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | | |
| 2 | 2 | 2 | 19 | 19 | 19 | 4 | 4 | 18 | 18 | 18 | 18 | 18 | 18 | 9 | 9 | 9 | 9 | 14 | 14 | 14 | 14 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | |
| 2 | 2 | 2 | 7 | 7 | 7 | 4 | 4 | 18 | 18 | 18 | 18 | 18 | 18 | 9 | 9 | 9 | 9 | 14 | 14 | 14 | 14 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | |
| 2 | 2 | 2 | 7 | 7 | 7 | 4 | 4 | 18 | 18 | 18 | 18 | 18 | 18 | 10 | 10 | 10 | 10 | 14 | 14 | 14 | 14 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | |
| 2 | 2 | 2 | 7 | 7 | 7 | 4 | 4 | 18 | 18 | 18 | 18 | 18 | 18 | 10 | 10 | 10 | 10 | 14 | 14 | 14 | 14 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | |
| 2 | 2 | 2 | 8 | 8 | 8 | 4 | 4 | 18 | 18 | 18 | 18 | 18 | 18 | 10 | 10 | 10 | 10 | 14 | 14 | 14 | 14 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | |
| 2 | 2 | 2 | 8 | 8 | 8 | 4 | 4 | 18 | 18 | 18 | 18 | 18 | 18 | 10 | 10 | 10 | 10 | 13 | 13 | 13 | 13 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | |
| 20 | 20 | 20 | 8 | 8 | 8 | 17 | 17 | 17 | 17 | 17 | 17 | 17 | 17 | 10 | 10 | 10 | 10 | 13 | 13 | 13 | 13 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | | |
| 20 | 20 | 20 | 20 | 20 | 20 | 17 | 17 | 17 | 17 | 17 | 17 | 17 | 17 | 10 | 10 | 10 | 10 | 13 | 13 | 13 | 13 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | |
| 20 | 20 | 20 | 20 | 20 | 20 | 17 | 17 | 17 | 17 | 17 | 17 | 17 | 17 | 12 | 12 | 12 | 12 | 13 | 13 | 13 | 13 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | |
| 20 | 20 | 20 | 20 | 20 | 20 | 17 | 17 | 17 | 17 | 17 | 17 | 17 | 17 | 12 | 12 | 12 | 12 | 12 | 12 | 12 | 12 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 |
| 20 | 20 | 20 | 20 | 20 | 20 | 17 | 17 | 17 | 17 | 17 | 17 | 17 | 17 | 12 | 12 | 12 | 12 | 12 | 12 | 12 | 12 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 |
| 20 | 20 | 20 | 20 | 20 | 20 | 17 | 17 | 17 | 17 | 17 | 17 | 17 | 17 | 12 | 12 | 12 | 12 | 12 | 12 | 12 | 12 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 |
| 20 | 20 | 20 | 20 | 20 | 20 | 17 | 17 | 17 | 17 | 17 | 17 | 17 | 17 | 12 | 12 | 12 | 12 | 12 | 12 | 12 | 12 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 |
| 20 | 20 | 20 | 20 | 20 | 20 | 17 | 17 | 17 | 17 | 17 | 17 | 17 | 17 | 12 | 12 | 12 | 12 | 12 | 12 | 12 | 12 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 |

Figura 7.4.8 Solución de la frontera de Pareto con elevado valor de FMP.

Si se consideran también las soluciones obtenidas con el empleo de un modelo geométrico continuo se observa que 40 de los 42 puntos de la frontera discreta obtenida (incluyendo a las soluciones de Wang) quedan dominados por una única solución histórica, la obtenida en (Anjos y Vanelli 2006), tal y como se puede observar en la Figura 7.4.9. Por tanto el presente trabajo aporta 2 soluciones a la frontera de Pareto del bicriterio Coste-FMP. Los dos puntos que se introducen en la nueva frontera absoluta del bicriterio son los mostrados en la siguiente tabla:

| Nº Sol | Código Solución | Coste | FMP |
|--------|---|---------|---------|
| 1 | 1-11-16-13-17-15-12-14-9-10-2-4-19-6-7-3-8-20-18-5 3 9+19+2 | 5013,36 | 0,30318 |
| 2 | 1-11-16-13-17-15-14-12-9-10-2-4-19-6-7-3-8-20-18-5 3 9+19+2 | 5168,70 | 0,3032 |

Tabla 7.4.2 Soluciones aportadas a la frontera de Pareto Coste-FMP.

En la Figura 7.4.9 se muestra la nueva frontera para el bicriterio Coste-FMP, formada por los dos puntos aportados y los 6 puntos de las soluciones históricas anteriormente citadas. También se sitúa la utopía de Pareto, con el coste de la solución 1 de (Tate y Smith 1995) y la forma media ponderada de la solución 3 de (Kim y Kim 1998).

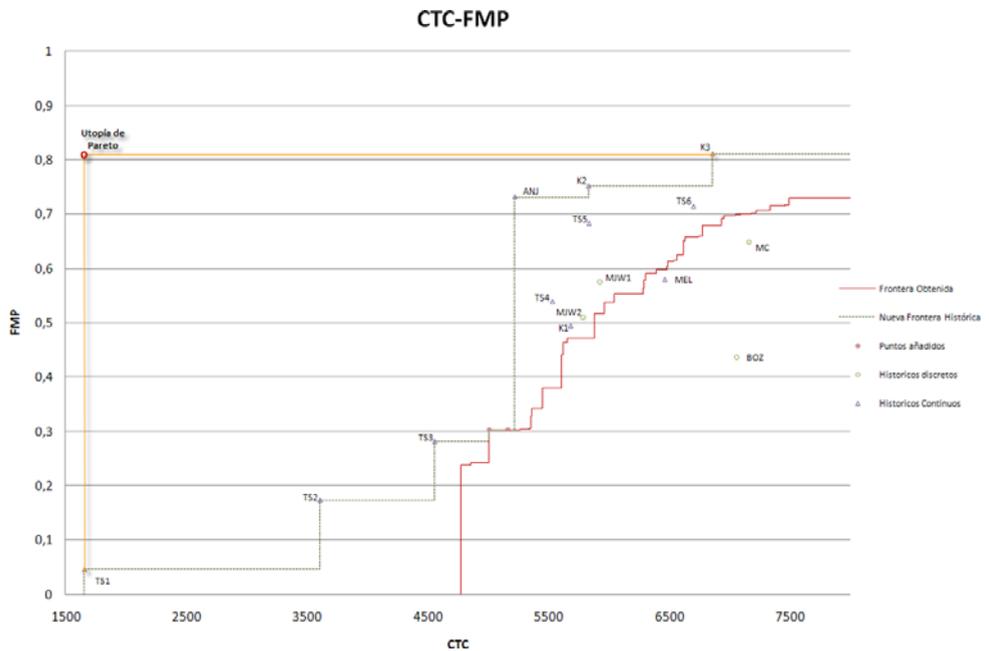


Figura 7.4.9 Nueva frontera de Pareto del bicriterio Coste-Forma Media Ponderada.

En la siguiente figura se muestra una de las soluciones aportadas a la frontera, con coste 5013.36 y forma media ponderada 0.303:

7.4.1.3 Frontera Coste-SRF

El último de los indicadores de configuración objeto del presente estudio es el SRF, introducido por (Wang, Hu y Ku 2005). Tal y como se comentó en capítulos anteriores, se trata de un indicador únicamente aplicable a modelos con una geometría discreta, por tanto solo se pueden comparar los resultados obtenidos con las soluciones históricas que emplean este tipo de modelo geométrico.

Se realizaron 50 lanzamientos independientes del algoritmo, deteniéndose la optimización tras detectar que había transcurrido más de 5 consecutivos sin producirse mejora alguna. En la Figura 7.4.11 se puede observar la variación de la frontera con los diferentes lanzamientos realizados.

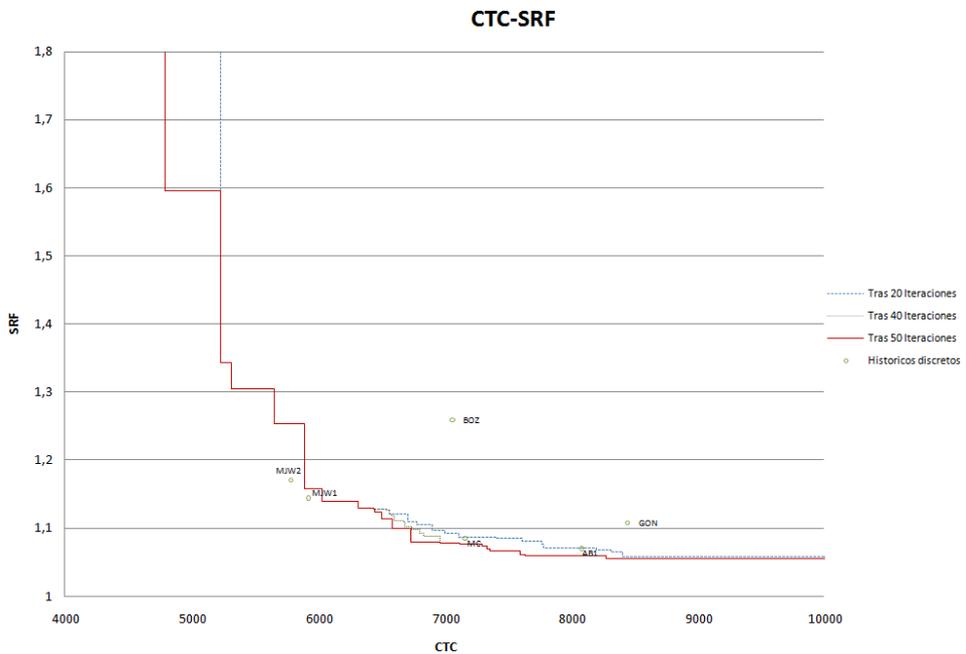


Figura 7.4.11 Evolución de la frontera de Pareto Coste-SRF.

En la Figura 7.4.12 se muestra la frontera final obtenida y todos los puntos que en algún momento han formado parte de la misma (el número de puntos es elevado, lo que da una idea de la dispersión que se ha producido durante toda la optimización del problema), así como las dos soluciones de (Wang, Hu y Ku 2005) que no son dominadas en la presente investigación, y que únicamente dominan a una de las soluciones obtenidas.

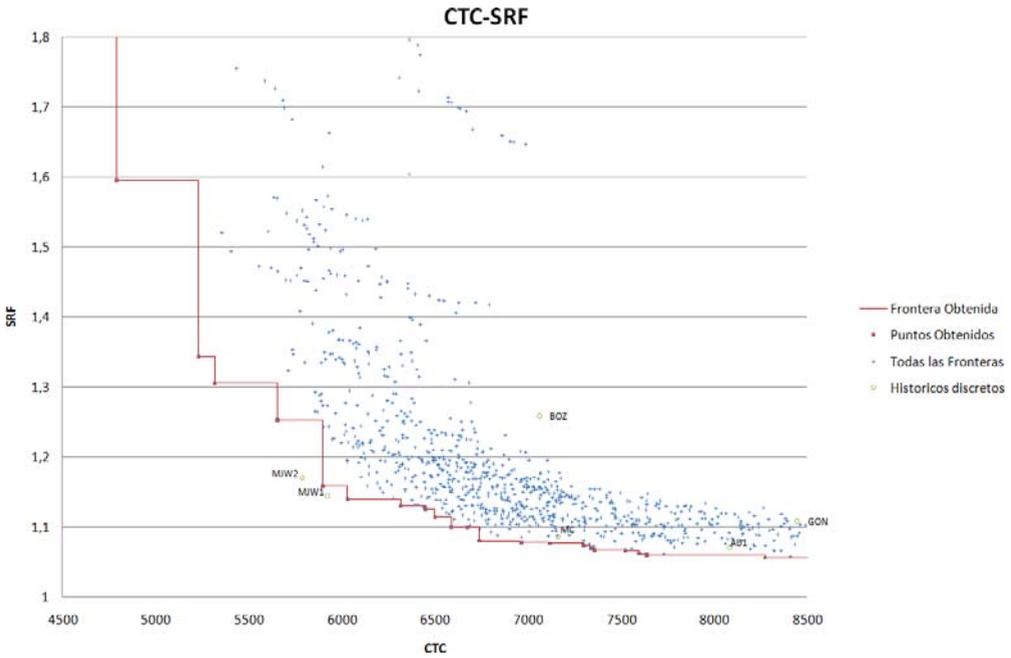


Figura 7.4.12 Frontera de Pareto Coste-SRF discreta.

Se añaden un gran número de soluciones a la frontera bicriterio coste-SRF, que queda configurada por 24 puntos, las obtenidas y las dos del artículo de (Wang, Hu y Ku 2005).

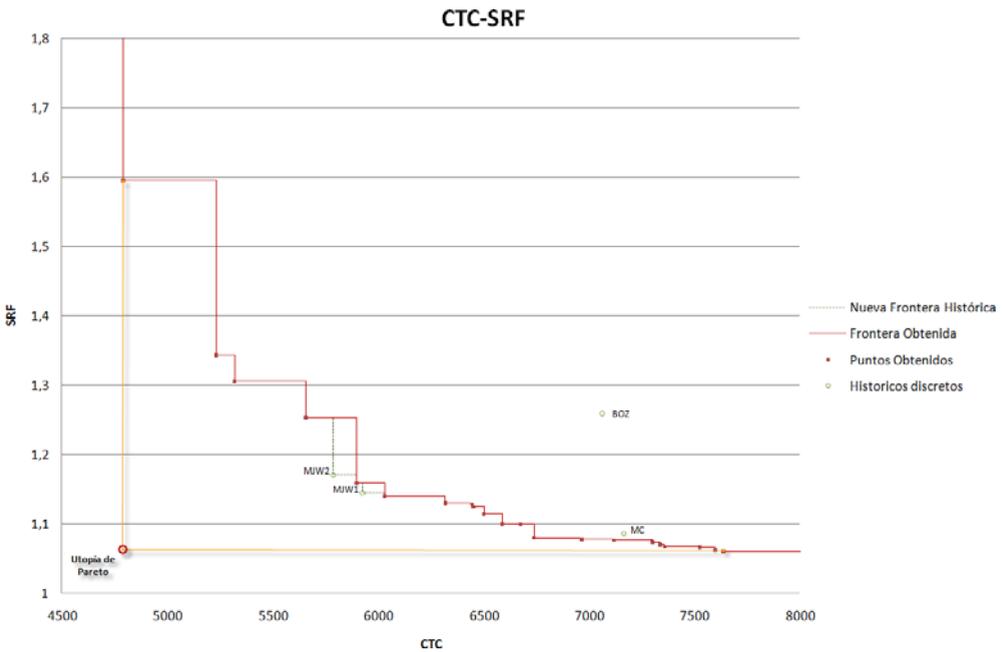


Figura 7.4.13 Nueva frontera de Pareto del bicriterio Coste-SRF.

En la Figura 7.4.13 se muestra la nueva frontera bicriterio (línea de trazos). Los puntos que se introducen en la nueva frontera absoluta del bicriterio son los siguientes:

| Nº Sol | Código Solución | Coste | SRF |
|--------|---|---------|------|
| 1 | 11-16-17-12-5-13-20-6-8-4-7-2-19-10-9-15-14-3-1-18 8 3+2+2+2+4+2+13+2 | 4793,27 | 1,6 |
| 2 | 11-16-17-13-1-3-14-9-10-19-12-15-18-5-2-6-4-7-8-20 7 2+2+2+3+2+10+9 | 5234,7 | 1,34 |
| 3 | 11-16-13-17-15-3-14-9-10-5-12-19-18-1-2-6-4-7-8-20 8 2+2+2+3+2+8+2+9 | 5321,43 | 1,31 |
| 4 | 11-16-17-1-12-5-13-15-14-10-3-9-18-19-2-6-4-7-8-20 7 2+2+2+5+5+5+9 | 5657,96 | 1,25 |
| 5 | 13-11-16-17-15-14-10-12-1-19-2-4-9-3-5-6-7-8-20-18 8 3+2+2+4+6+6+4+3 | 5900,88 | 1,16 |
| 6 | 13-11-16-17-9-14-10-12-1-15-2-4-19-3-5-6-7-8-20-18 8 3+2+2+4+6+6+4+3 | 6033,41 | 1,14 |
| 7 | 11-16-17-15-14-10-12-18-19-13-3-5-8-7-9-6-4-2-20-1 8 2+2+3+4+6+4+3+6 | 6320,16 | 1,13 |
| 8 | 5-20-18-6-8-7-4-2-15-1-13-14-3-9-19-10-16-12-17-11 8 2+2+3+4+6+4+3+6 | 6447,09 | 1,13 |
| 9 | 5-7-8-20-9-2-6-4-18-10-19-3-15-14-12-17-11-13-16-1 8 3+3+2+5+5+4+2+6 | 6453,36 | 1,12 |
| 10 | 5-7-8-20-9-2-6-4-18-10-19-3-15-14-12-17-11-13-16-1 7 3+3+2+5+5+4+8 | 6503,61 | 1,11 |
| 11 | 5-7-8-20-9-2-6-4-18-19-10-3-15-14-12-17-11-13-16-1 7 3+3+2+5+7+4+6 | 6590,64 | 1,1 |
| 12 | 5-7-8-20-9-2-6-4-18-10-19-3-15-14-12-17-11-13-16-1 7 3+3+2+5+7+4+6 | 6677,73 | 1,1 |
| 13 | 6-7-2-1-4-8-20-19-3-9-17-18-10-14-15-5-12-16-11-13 7 3+3+3+3+6+5+7 | 6740,73 | 1,08 |
| 14 | 6-7-5-1-2-8-20-4-3-9-17-19-14-15-13-10-12-18-16-11 7 3+3+3+2+6+4+9 | 6967,89 | 1,08 |
| 15 | 6-4-20-7-2-19-3-8-1-5-18-10-14-9-15-16-17-12-13-11 7 3+3+3+3+5+7+6 | 7120,57 | 1,08 |
| 16 | 7-8-17-20-9-18-19-4-2-6-3-1-10-14-5-15-13-12-16-11 8 3+2+3+4+3+4+5+6 | 7302,72 | 1,07 |
| 17 | 6-4-20-7-2-19-3-8-1-5-10-18-14-9-15-16-17-12-13-11 7 3+3+3+3+5+7+6 | 7339,24 | 1,07 |
| 18 | 6-20-18-8-7-5-10-14-3-19-2-4-13-1-15-12-9-16-17-11 8 2+2+3+6+6+3+3+5 | 7359,82 | 1,07 |
| 19 | 6-4-20-7-2-19-3-8-1-14-9-10-13-18-15-16-17-12-5-11 7 3+3+3+3+5+7+6 | 7525,89 | 1,07 |
| 20 | 6-4-20-7-2-19-10-8-1-14-9-3-13-18-15-16-17-12-5-11 7 3+3+3+3+5+7+6 | 7600,36 | 1,06 |
| 21 | 6-7-5-1-2-4-19-9-8-20-17-3-14-15-13-10-12-18-16-11 7 3+3+3+2+6+6+7 | 7640,37 | 1,06 |
| 22 | 6-13-20-8-7-9-1-4-11-19-2-3-14-10-12-15-5-17-16-18 7 3+3+3+4+5+3+9 | 8276,33 | 1,06 |

Tabla 7.4.3 Soluciones aportadas a la frontera de Pareto Coste-SRF.

En las siguientes figuras se adjuntan dos de las soluciones aportadas a la frontera bicriterio, en concreto la que tiene un menor valor de coste (4793.27) de todas las obtenidas, a costa de un elevado valor de SRF (1.6) y la que tiene un menor valor de SRF (1.06) a costa de un elevado valor de coste (7600).

| | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|
| 13 | 13 | 13 | 16 | 16 | 16 | 16 | 17 | 17 | 15 | 15 | 15 | 15 | 15 | 15 | 15 | 15 | 15 | 3 | 3 | 3 | 3 | 3 | 3 | 5 | 5 | 5 | 5 | 18 | 18 | 18 |
| 13 | 13 | 13 | 16 | 16 | 16 | 16 | 17 | 17 | 17 | 15 | 15 | 15 | 15 | 15 | 15 | 15 | 15 | 3 | 3 | 3 | 3 | 3 | 3 | 5 | 5 | 5 | 5 | 18 | 18 | 18 |
| 13 | 13 | 13 | 16 | 16 | 16 | 16 | 17 | 17 | 17 | 17 | 15 | 15 | 15 | 15 | 15 | 15 | 15 | 3 | 3 | 3 | 3 | 3 | 3 | 5 | 5 | 5 | 5 | 18 | 18 | 18 |
| 13 | 13 | 13 | 16 | 16 | 16 | 16 | 17 | 17 | 17 | 17 | 15 | 15 | 15 | 15 | 15 | 15 | 15 | 3 | 3 | 3 | 3 | 3 | 3 | 5 | 5 | 5 | 5 | 18 | 18 | 18 |
| 13 | 13 | 13 | 16 | 16 | 16 | 16 | 17 | 17 | 17 | 17 | 14 | 14 | 14 | 14 | 14 | 14 | 14 | 3 | 3 | 3 | 9 | 9 | 9 | 6 | 6 | 5 | 5 | 18 | 18 | 18 |
| 13 | 13 | 13 | 16 | 16 | 16 | 16 | 17 | 17 | 17 | 17 | 14 | 14 | 14 | 14 | 14 | 14 | 14 | 9 | 9 | 9 | 9 | 9 | 9 | 6 | 6 | 6 | 6 | 18 | 18 | 18 |
| 11 | 11 | 11 | 16 | 16 | 16 | 16 | 17 | 17 | 17 | 17 | 14 | 14 | 14 | 14 | 14 | 14 | 14 | 4 | 4 | 4 | 4 | 4 | 4 | 6 | 6 | 6 | 6 | 18 | 18 | 18 |
| 11 | 11 | 11 | 16 | 16 | 16 | 16 | 17 | 17 | 17 | 17 | 14 | 14 | 14 | 14 | 14 | 14 | 14 | 4 | 4 | 4 | 4 | 4 | 4 | 6 | 6 | 6 | 6 | 18 | 18 | 18 |
| 11 | 11 | 11 | 16 | 16 | 16 | 16 | 17 | 17 | 17 | 17 | 10 | 10 | 10 | 10 | 10 | 10 | 10 | 4 | 4 | 4 | 4 | 4 | 4 | 6 | 6 | 6 | 6 | 18 | 18 | 18 |
| 11 | 11 | 11 | 16 | 16 | 16 | 16 | 17 | 17 | 17 | 17 | 10 | 10 | 10 | 10 | 10 | 10 | 10 | 2 | 2 | 2 | 2 | 2 | 2 | 7 | 7 | 7 | 7 | 18 | 18 | 18 |
| 11 | 11 | 11 | 16 | 16 | 16 | 16 | 17 | 17 | 17 | 17 | 10 | 10 | 10 | 10 | 10 | 10 | 10 | 2 | 2 | 2 | 2 | 2 | 2 | 7 | 7 | 7 | 7 | 18 | 18 | 18 |
| 11 | 11 | 11 | 16 | 16 | 16 | 16 | 17 | 17 | 17 | 17 | 10 | 10 | 10 | 10 | 10 | 10 | 10 | 2 | 2 | 2 | 2 | 2 | 2 | 7 | 8 | 8 | 8 | 18 | 18 | 18 |
| 11 | 11 | 11 | 16 | 16 | 16 | 16 | 17 | 17 | 17 | 17 | 12 | 12 | 12 | 12 | 12 | 12 | 12 | 19 | 19 | 19 | 19 | 19 | 19 | 8 | 8 | 8 | 8 | 18 | 18 | 18 |
| 11 | 11 | 11 | 16 | 16 | 16 | 16 | 17 | 17 | 17 | 17 | 12 | 12 | 12 | 12 | 12 | 12 | 12 | 19 | 19 | 19 | 19 | 19 | 19 | 8 | 8 | 20 | 20 | 20 | 18 | 18 |
| 11 | 11 | 11 | 16 | 16 | 16 | 16 | 17 | 17 | 17 | 17 | 12 | 12 | 12 | 12 | 12 | 12 | 12 | 19 | 19 | 19 | 19 | 19 | 19 | 20 | 20 | 20 | 20 | 20 | 20 | 20 |
| 11 | 11 | 11 | 16 | 16 | 16 | 16 | 17 | 17 | 17 | 17 | 12 | 12 | 12 | 12 | 12 | 12 | 12 | 19 | 19 | 19 | 19 | 19 | 19 | 20 | 20 | 20 | 20 | 20 | 20 | 20 |
| 11 | 11 | 11 | 16 | 16 | 16 | 16 | 17 | 17 | 17 | 17 | 12 | 12 | 12 | 12 | 12 | 12 | 12 | 19 | 19 | 19 | 1 | 1 | 1 | 20 | 20 | 20 | 20 | 20 | 20 | 20 |
| 11 | 11 | 11 | 16 | 16 | 16 | 16 | 17 | 17 | 17 | 17 | 12 | 12 | 12 | 12 | 12 | 12 | 12 | 1 | 1 | 1 | 1 | 1 | 1 | 20 | 20 | 20 | 20 | 20 | 20 | 20 |
| 11 | 11 | 11 | 16 | 16 | 16 | 16 | 17 | 17 | 17 | 17 | 12 | 12 | 12 | 12 | 12 | 12 | 12 | 1 | 1 | 1 | 1 | 1 | 1 | 20 | 20 | 20 | 20 | 20 | 20 | 20 |
| 11 | 11 | 11 | 16 | 16 | 16 | 16 | 17 | 17 | 17 | 17 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 20 | 20 | 20 | 20 | 20 | 20 | 20 |

Figura 7.4.14 Solución aportada nº 5 a la frontera Coste-SRF.

| | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|
| 6 | 6 | 6 | 19 | 19 | 19 | 19 | 19 | 19 | 3 | 3 | 3 | 3 | 3 | 3 | 3 | 3 | 17 | 17 | 17 | 17 | 17 | 17 | 12 | 12 | 12 | 12 | 12 | 12 | | |
| 6 | 6 | 6 | 19 | 19 | 19 | 19 | 19 | 19 | 3 | 3 | 3 | 3 | 3 | 3 | 3 | 3 | 17 | 17 | 17 | 17 | 17 | 17 | 12 | 12 | 12 | 12 | 12 | 12 | 12 | |
| 6 | 6 | 6 | 19 | 19 | 19 | 19 | 19 | 19 | 3 | 3 | 3 | 3 | 3 | 3 | 3 | 3 | 17 | 17 | 17 | 17 | 17 | 17 | 12 | 12 | 12 | 12 | 12 | 12 | 12 | |
| 6 | 6 | 6 | 19 | 19 | 19 | 19 | 19 | 19 | 3 | 3 | 3 | 13 | 13 | 13 | 13 | 13 | 17 | 17 | 17 | 17 | 17 | 17 | 12 | 12 | 12 | 12 | 12 | 12 | 12 | |
| 6 | 6 | 6 | 2 | 2 | 2 | 19 | 19 | 19 | 9 | 9 | 9 | 13 | 13 | 13 | 13 | 13 | 17 | 17 | 17 | 17 | 17 | 17 | 12 | 12 | 12 | 12 | 12 | 12 | 12 | |
| 6 | 6 | 6 | 2 | 2 | 2 | 10 | 10 | 10 | 9 | 9 | 9 | 13 | 13 | 13 | 13 | 13 | 17 | 17 | 17 | 17 | 17 | 17 | 12 | 12 | 12 | 12 | 12 | 12 | 12 | |
| 4 | 4 | 4 | 2 | 2 | 2 | 10 | 10 | 10 | 9 | 9 | 9 | 18 | 18 | 13 | 13 | 13 | 17 | 17 | 17 | 17 | 17 | 17 | 12 | 12 | 12 | 12 | 12 | 12 | 12 | |
| 4 | 4 | 4 | 2 | 2 | 2 | 10 | 10 | 10 | 14 | 14 | 14 | 18 | 18 | 18 | 18 | 18 | 17 | 17 | 17 | 17 | 17 | 17 | 12 | 12 | 12 | 12 | 12 | 12 | 12 | |
| 4 | 4 | 4 | 2 | 2 | 2 | 10 | 10 | 10 | 14 | 14 | 14 | 18 | 18 | 18 | 18 | 18 | 17 | 17 | 17 | 17 | 17 | 17 | 5 | 5 | 5 | 5 | 5 | 5 | 5 | |
| 4 | 4 | 4 | 2 | 2 | 2 | 10 | 10 | 10 | 14 | 14 | 14 | 18 | 18 | 18 | 18 | 18 | 16 | 16 | 16 | 16 | 16 | 16 | 5 | 5 | 5 | 5 | 5 | 5 | 5 | |
| 4 | 4 | 4 | 7 | 7 | 7 | 10 | 10 | 10 | 14 | 14 | 14 | 18 | 18 | 18 | 18 | 18 | 16 | 16 | 16 | 16 | 16 | 16 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | |
| 4 | 4 | 4 | 7 | 7 | 7 | 10 | 10 | 10 | 14 | 14 | 14 | 18 | 18 | 18 | 18 | 18 | 16 | 16 | 16 | 16 | 16 | 16 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | |
| 20 | 20 | 20 | 7 | 7 | 7 | 10 | 10 | 10 | 14 | 14 | 14 | 18 | 18 | 18 | 18 | 18 | 16 | 16 | 16 | 16 | 16 | 16 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | |
| 20 | 20 | 20 | 20 | 20 | 20 | 8 | 8 | 8 | 14 | 14 | 14 | 18 | 18 | 18 | 18 | 18 | 16 | 16 | 16 | 16 | 16 | 16 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | |
| 20 | 20 | 20 | 20 | 20 | 20 | 8 | 8 | 8 | 14 | 14 | 14 | 15 | 18 | 18 | 18 | 18 | 16 | 16 | 16 | 16 | 16 | 16 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | |
| 20 | 20 | 20 | 20 | 20 | 20 | 8 | 8 | 8 | 1 | 1 | 1 | 15 | 15 | 15 | 15 | 15 | 16 | 16 | 16 | 16 | 16 | 16 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | |
| 20 | 20 | 20 | 20 | 20 | 20 | 1 | 1 | 1 | 1 | 1 | 1 | 15 | 15 | 15 | 15 | 15 | 16 | 16 | 16 | 16 | 16 | 16 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | |
| 20 | 20 | 20 | 20 | 20 | 20 | 1 | 1 | 1 | 1 | 1 | 1 | 15 | 15 | 15 | 15 | 15 | 16 | 16 | 16 | 16 | 16 | 16 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | |
| 20 | 20 | 20 | 20 | 20 | 20 | 1 | 1 | 1 | 1 | 1 | 1 | 15 | 15 | 15 | 15 | 15 | 16 | 16 | 16 | 16 | 16 | 16 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | |
| 20 | 20 | 20 | 20 | 20 | 20 | 1 | 1 | 1 | 1 | 1 | 1 | 15 | 15 | 15 | 15 | 15 | 15 | 16 | 16 | 16 | 16 | 16 | 16 | 11 | 11 | 11 | 11 | 11 | 11 | 11 |

Figura 7.4.15 Solución aportada nº 20 a la frontera Coste-SRF.

7.4.1.4 Frontera Coste-Forma Mínima

El primero de los indicadores de actividad que se ha empleado en el presente trabajo es la forma. Se persigue maximizar el valor de la actividad con peor forma de toda la configuración. Así el resto de los valores de forma de las actividades serán superiores, aumentando la calidad de la configuración.

En este experimento se realizaron 40 lanzamientos independientes del algoritmo, obteniendo una frontera de Pareto estable desde los primeros momentos del mismo. Se detuvo el experimento después de que trascurrieran 5 lanzamientos sin mejora. En la Figura 7.4.16 se observa la poca evolución de la misma, así como la posición de las distintas soluciones históricas discretas respecto a la frontera obtenida.

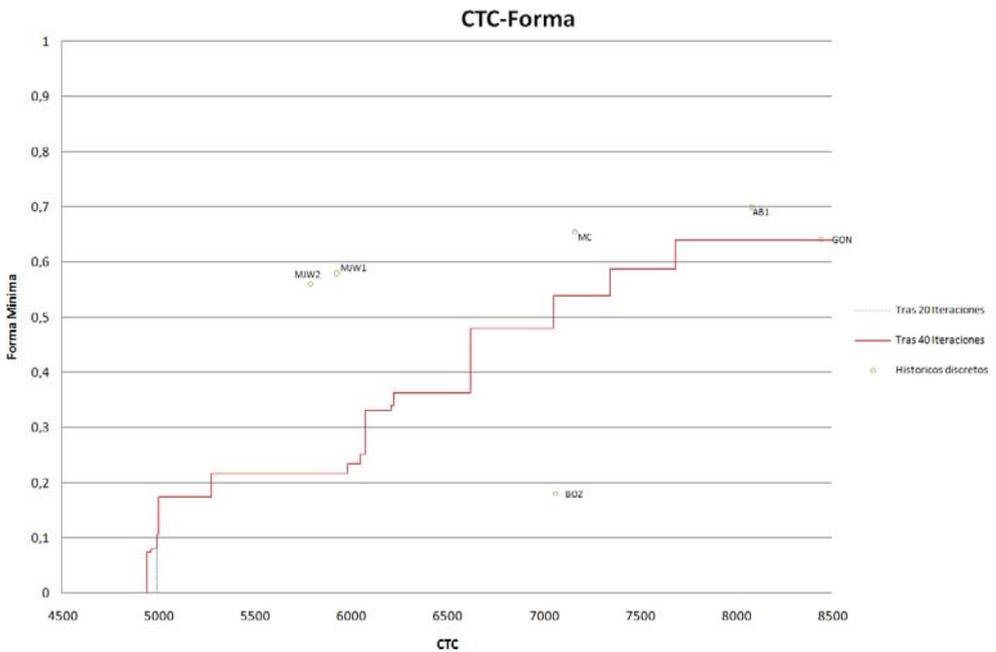


Figura 7.4.16 Evolución de la frontera de Pareto Coste-Forma Mínima.

La solución de la frontera obtenida con un mejor valor de forma mínima (0.63) y un mayor valor de coste (7500) es la mostrada en la siguiente figura:

| | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
|---|---|---|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|
| 6 | 6 | 6 | 18 | 18 | 18 | 18 | 18 | 17 | 17 | 17 | 17 | 17 | 17 | 17 | 17 | 12 | 12 | 12 | 12 | 12 | 12 | 12 | 12 | 12 | 13 | 13 | 13 | 13 | 13 |
| 6 | 6 | 6 | 18 | 18 | 18 | 18 | 18 | 17 | 17 | 17 | 17 | 17 | 17 | 17 | 17 | 12 | 12 | 12 | 12 | 12 | 12 | 12 | 12 | 12 | 13 | 13 | 13 | 13 | 13 |
| 6 | 6 | 6 | 18 | 18 | 18 | 18 | 18 | 17 | 17 | 17 | 17 | 17 | 17 | 17 | 17 | 12 | 12 | 12 | 12 | 14 | 14 | 14 | 12 | 13 | 13 | 13 | 13 | 13 | |
| 6 | 6 | 6 | 18 | 18 | 18 | 18 | 18 | 17 | 17 | 17 | 17 | 17 | 17 | 17 | 17 | 12 | 12 | 12 | 12 | 14 | 14 | 14 | 14 | 10 | 10 | 13 | 13 | 13 | |
| 6 | 6 | 6 | 18 | 18 | 18 | 18 | 18 | 17 | 17 | 17 | 17 | 17 | 17 | 17 | 17 | 12 | 12 | 12 | 12 | 14 | 14 | 14 | 14 | 10 | 10 | 10 | 10 | 10 | |
| 6 | 6 | 6 | 18 | 18 | 18 | 18 | 18 | 17 | 17 | 17 | 17 | 17 | 17 | 17 | 17 | 12 | 12 | 12 | 12 | 14 | 14 | 14 | 14 | 10 | 10 | 10 | 10 | 10 | |
| 2 | 2 | 2 | 18 | 18 | 18 | 18 | 18 | 17 | 17 | 17 | 19 | 19 | 19 | 19 | 17 | 12 | 12 | 12 | 12 | 14 | 14 | 14 | 14 | 10 | 10 | 10 | 10 | 10 | |
| 2 | 2 | 2 | 4 | 4 | 4 | 18 | 18 | 17 | 17 | 17 | 19 | 19 | 19 | 19 | 19 | 12 | 12 | 12 | 12 | 14 | 14 | 14 | 14 | 10 | 10 | 10 | 10 | 10 | |
| 2 | 2 | 2 | 4 | 4 | 4 | 18 | 18 | 17 | 17 | 9 | 19 | 19 | 19 | 19 | 19 | 12 | 15 | 15 | 15 | 3 | 3 | 3 | 14 | 10 | 10 | 5 | 5 | 5 | |
| 2 | 2 | 2 | 4 | 4 | 4 | 18 | 18 | 9 | 9 | 9 | 19 | 19 | 19 | 19 | 19 | 15 | 15 | 15 | 15 | 3 | 3 | 3 | 3 | 5 | 5 | 5 | 5 | 5 | |
| 2 | 2 | 2 | 4 | 4 | 4 | 20 | 20 | 9 | 9 | 9 | 16 | 19 | 19 | 19 | 19 | 15 | 15 | 15 | 15 | 3 | 3 | 3 | 3 | 5 | 5 | 5 | 5 | 5 | |
| 2 | 2 | 2 | 4 | 4 | 4 | 20 | 20 | 9 | 9 | 9 | 16 | 16 | 16 | 16 | 16 | 15 | 15 | 15 | 15 | 3 | 3 | 3 | 3 | 5 | 5 | 5 | 5 | 5 | |
| 7 | 7 | 7 | 4 | 4 | 4 | 20 | 20 | 20 | 20 | 20 | 16 | 16 | 16 | 16 | 16 | 15 | 15 | 15 | 15 | 3 | 3 | 3 | 3 | 11 | 11 | 11 | 11 | 11 | |
| 7 | 7 | 7 | 8 | 8 | 8 | 20 | 20 | 20 | 20 | 20 | 16 | 16 | 16 | 16 | 16 | 15 | 15 | 15 | 15 | 3 | 3 | 3 | 3 | 11 | 11 | 11 | 11 | 11 | |
| 7 | 7 | 7 | 8 | 8 | 8 | 20 | 20 | 20 | 20 | 20 | 16 | 16 | 16 | 16 | 16 | 15 | 15 | 15 | 15 | 3 | 3 | 3 | 3 | 11 | 11 | 11 | 11 | 11 | |
| 1 | 1 | 1 | 8 | 8 | 8 | 20 | 20 | 20 | 20 | 20 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | |
| 1 | 1 | 1 | 1 | 1 | 1 | 20 | 20 | 20 | 20 | 20 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | |
| 1 | 1 | 1 | 1 | 1 | 1 | 20 | 20 | 20 | 20 | 20 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | |
| 1 | 1 | 1 | 1 | 1 | 1 | 20 | 20 | 20 | 20 | 20 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 16 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | |

Figura 7.4.17 Solución de la frontera con mejor forma.

Si se combinan las soluciones de la frontera obtenida para este bicriterio con las soluciones históricas discretas, se obtiene la frontera discreta, mostrada en la siguiente figura, en la que también se incluyen aquellas soluciones que en algún momento han formado parte de la misma. La frontera está compuesta por 10 puntos, incluyendo las 4 soluciones históricas, que controlan la zona de elevados valores de forma mínima.

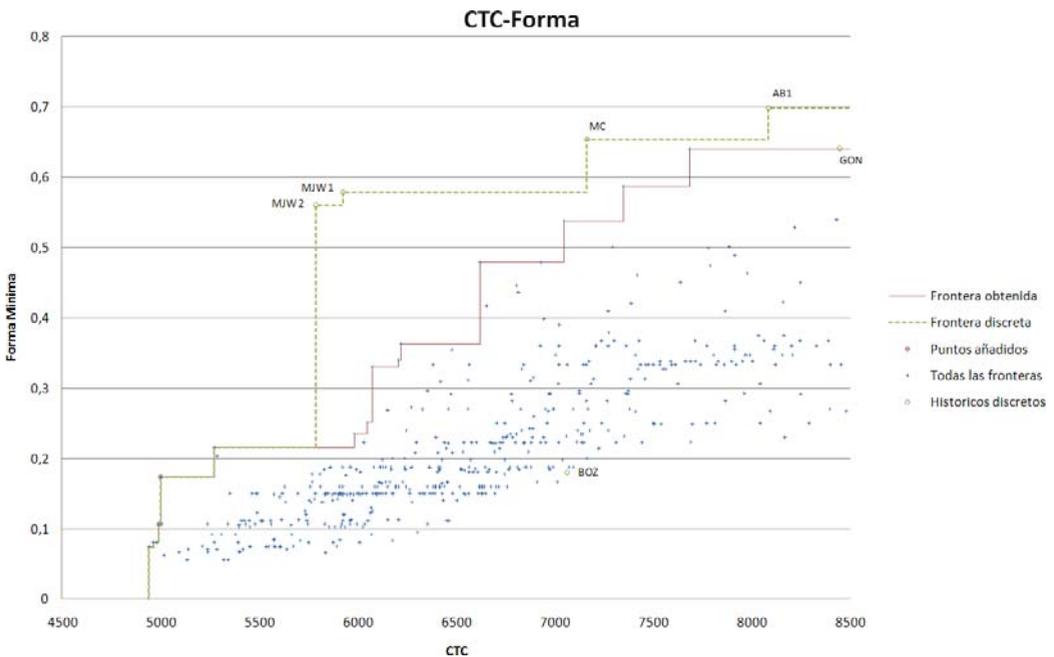


Figura 7.4.18 Nueva frontera de Pareto discreta para el bicriterio Coste-Forma Mínima.

La frontera total se construye uniendo los puntos de las soluciones históricas continuas y discretas con las obtenidas en el presente trabajo se aporta en la Figura 7.4.19. Se han obtenido dos nuevas soluciones que completan la frontera de Pareto, que son los mostrados en la siguiente tabla:

| Nº Sol | Código Solución | Coste | Forma Min |
|--------|---|---------|-----------|
| 1 | 11-16-1-17-12-6-7-2-8-4-19-3-9-10-14-15-5-18-13-20 8 3+2+2+2+2+13+4 | 4991,75 | 0,11 |
| 2 | 11-5-16-15-17-12-6-3-14-10-19-4-9-2-7-13-8-20-1-18 8 2+2+3+3+2+2+13+3 | 5002,3 | 0,17 |

Tabla 7.4.4 Soluciones aportadas a la frontera de Pareto Coste-Forma Mínima.

En la figura se incluye también el punto de utopía de Pareto, conformado por el coste de la solución 1 de (Tate y Smith 1995) y la forma de la solución 3 de (Kim y Kim 1998).

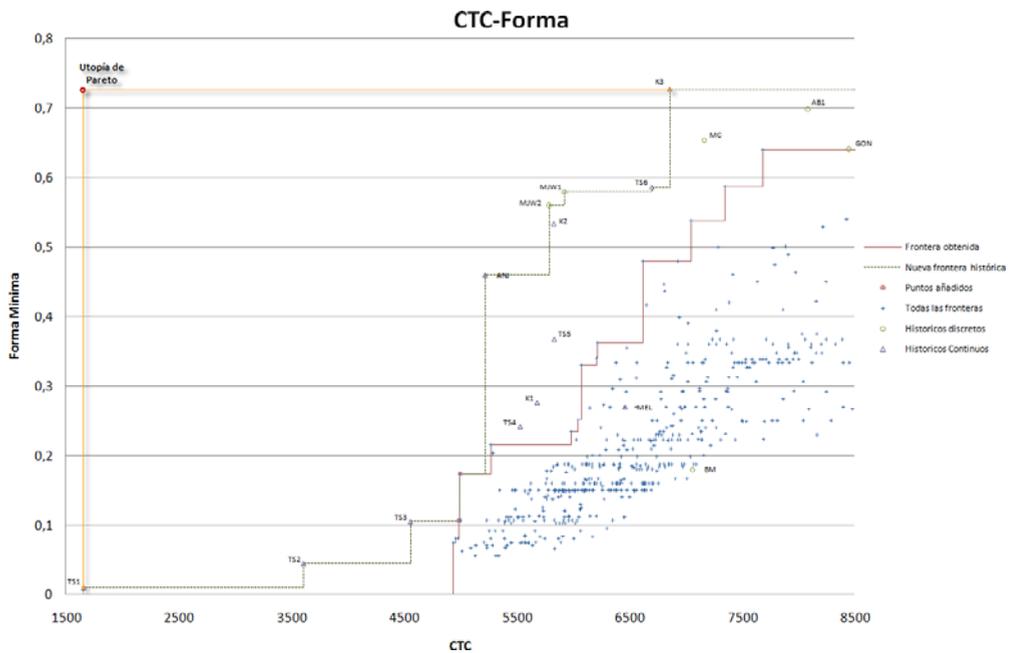


Figura 7.4.19 Nueva frontera de Pareto del bicriterio Coste-Forma Mínima.

Las soluciones aportadas por el presente trabajo se encuentran en la parte baja de la frontera, por tanto tienen valores de forma mínima muy bajos. En la siguiente figura se muestra la solución aportada nº1, que tiene un coste de 4991.75 y una forma mínima de 0.11:

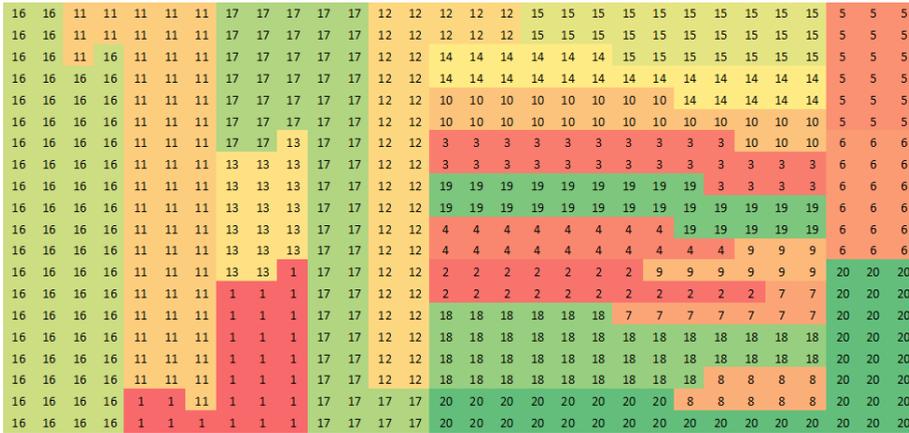


Figura 7.4.20 Solución aportada nº 1 a la frontera Coste-Forma Mínima.

7.4.1.5 Frontera Coste-Robustez

El segundo de los indicadores de actividad empleados es la robustez, nuevamente se maximiza el valor del valor mínimo de la robustez de las actividades del problema. Los valores de las soluciones encontradas en la bibliografía y que emplean un marco geométrico continuo tienen valores de la robustez muy aceptables. En la Figura 7.4.21 se aporta la evolución de la frontera obtenida en el presente trabajo. Se realizaron lanzamientos independientes y se detuvo el experimento tras el número 63 al detectar que habían transcurrido 5 son mejorar los resultados obtenidos.

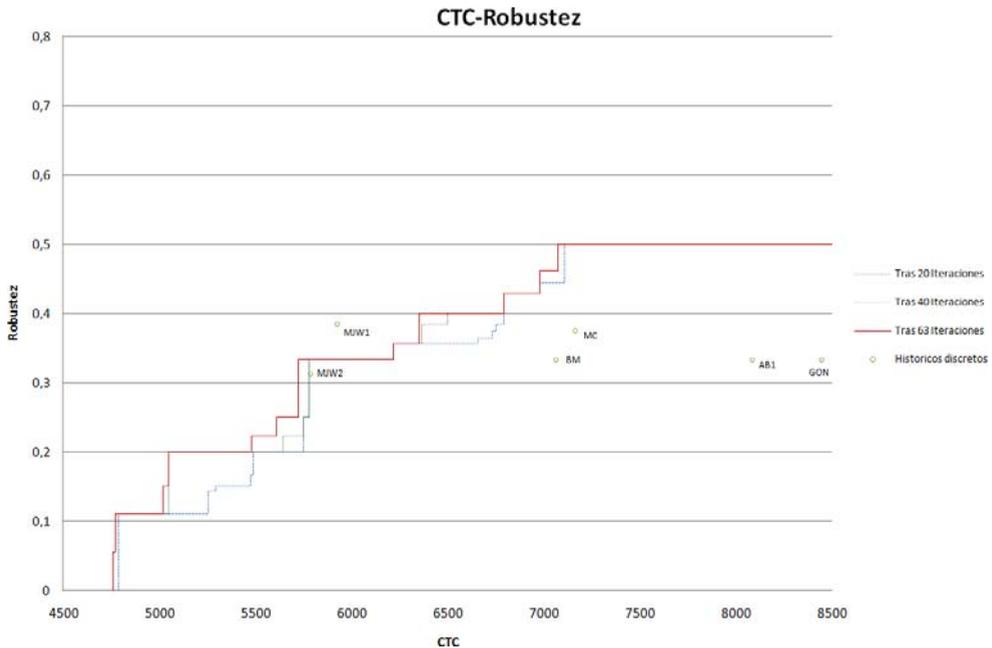


Figura 7.4.21 Evolución de la frontera de Pareto Coste-Robustez Mínima.

La solución de la frontera obtenida con un mayor valor de Robustez es la mostrada en la siguiente figura:

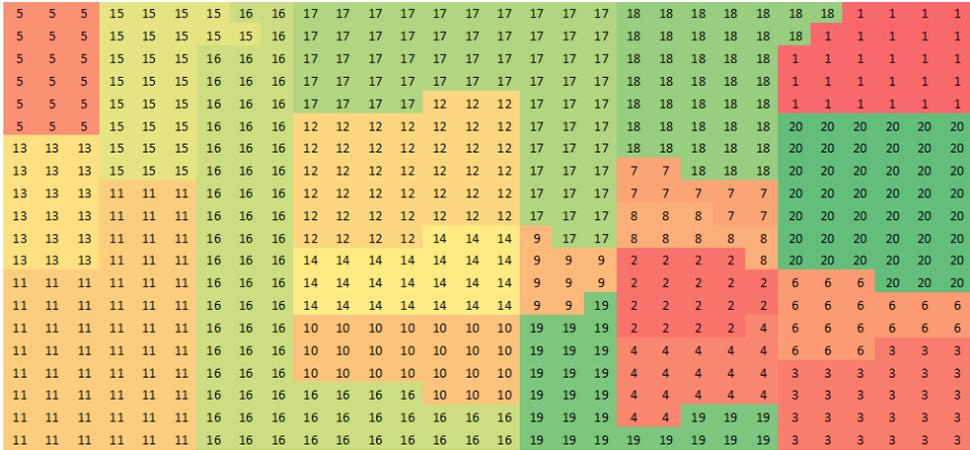


Figura 7.4.22 Solución obtenida con mayor Robustez Mínima.

Se incluye la solución 1 de (Wang, Hu y Ku 2005), para conformar la frontera de Pareto discreta del bicriterio Robustez-Coste.

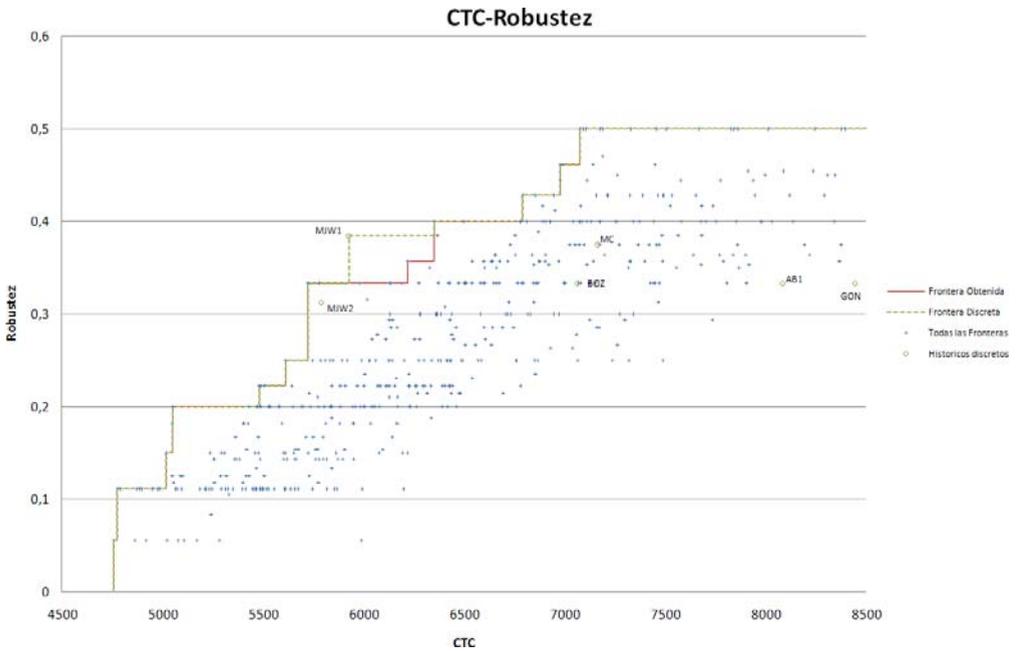


Figura 7.4.23 Evolución de la frontera de Pareto Coste-Robustez Mínima.

Si se combinan las soluciones de la frontera discreta con las soluciones continuas se obtiene la frontera de Pareto del bicriterio coste-robustez. Se introducen cuatro puntos en la nueva frontera absoluta y se muestran en la siguiente tabla:

| Nº Sol | Código Solución | Coste | Robustez Min |
|--------|---|---------|--------------|
| 1 | 11-16-17-12-15-14-9-10-4-3-19-2-7-1-8-5-20-6-13-18 7 2+2+2+2+18+2+2 | 4775,11 | 0,11 |
| 2 | 11-16-15-13-14-9-10-12-17-5-1-3-4-2-7-19-8-20-6-18 8 3+2+2+8+2+9+2+2 | 5019,46 | 0,15 |
| 3 | 16-11-17-12-13-15-14-10-3-19-4-9-2-1-18-7-8-6-5-20 8 2+2+3+3+2+12+4+2 | 5049,32 | 0,18 |
| 4 | 16-11-17-12-15-13-14-10-3-19-4-9-2-1-18-7-8-6-5-20 8 2+2+3+3+2+12+4+2 | 5052,6 | 0,2 |

Tabla 7.4.5 Soluciones aportadas a la frontera de Pareto Coste-Robustez Mínima.

En la siguiente figura se muestra la frontera de Pareto final del problema, formada por los 4 puntos aportados y por 7 de las soluciones obtenidas de la bibliografía, así como la utopía de Pareto, que está conformado por las mismas soluciones que en el anterior bicriterio.

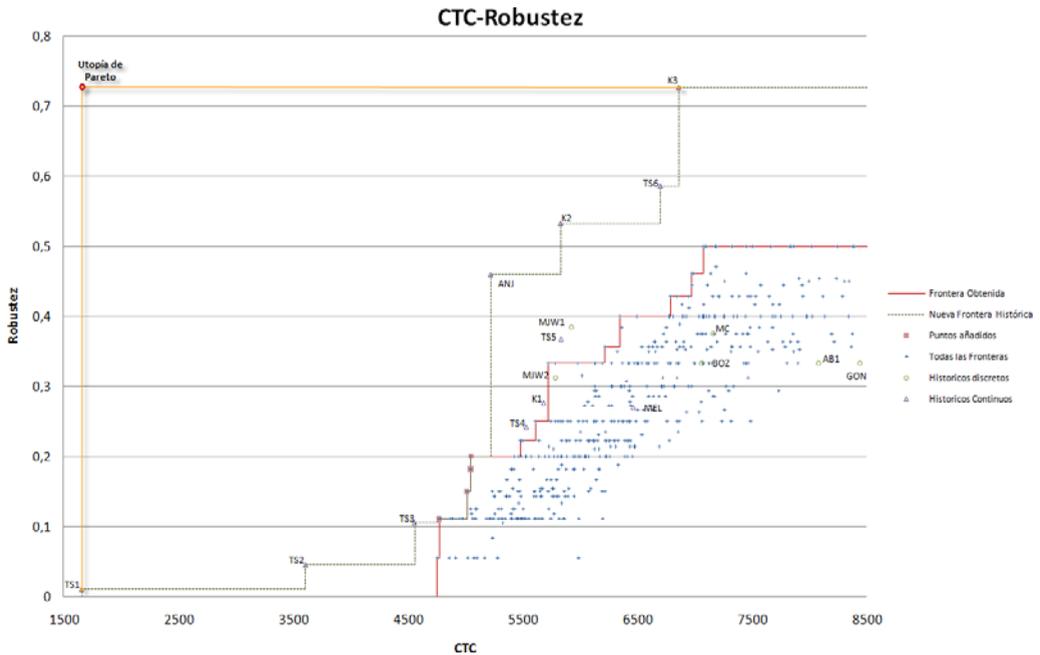


Figura 7.4.24 Nueva frontera de Pareto del bicriterio Coste-Robustez Mínima.

La solución aportada más cercana a la utopía de Pareto es la nº4 de la tabla anterior y se representa en la siguiente figura:

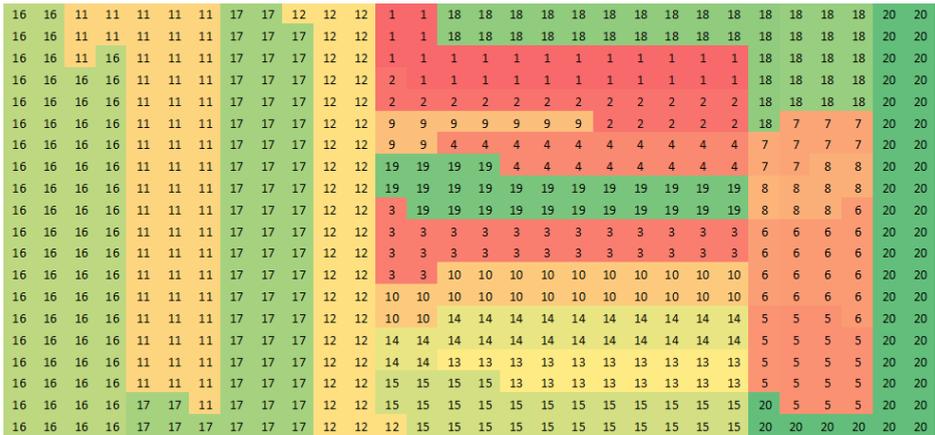


Figura 7.4.25 Solución aportada nº 4 a la frontera Coste-Robustez Mínima.

7.4.1.6 Frontera Coste-Compacidad

El último de los indicadores de actividad empleados es la compacidad, que tal y como se comentó en capítulos anteriores es un indicador que deba ser empleado únicamente en modelos geométricos discretos, pues en los continuos siempre alcanza su valor máximo tal y como se puede observar en la siguiente figura.

Se realizan 50 lanzamientos deteniéndose el experimento, al igual que en el resto de criterios, cuando se obtienen 5 seguidos sin que se produzca mejora de la frontera. La evolución de la misma se plasma en la Figura 7.4.26.

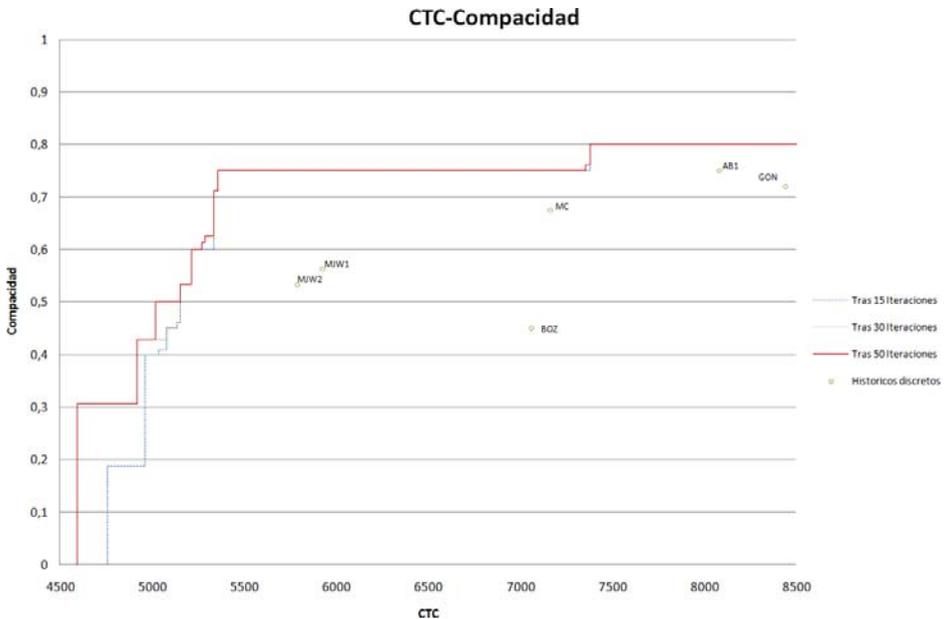


Figura 7.4.26 Evolución de la frontera de Pareto Coste-Compacidad.

Al no considerar las soluciones que emplean un modelo geométrico continuo, se introducen un gran número de puntos en la nueva frontera absoluta del bicriterio, como son los mostrados en la Tabla 7.4.1. En la Figura 7.4.27 se representa la frontera de Pareto final con todas las soluciones que han formado parte en algún momento de la misma y como referencia se muestran también las soluciones continuas (con compacidad unitaria) y la utopía de Pareto para este bicriterio.

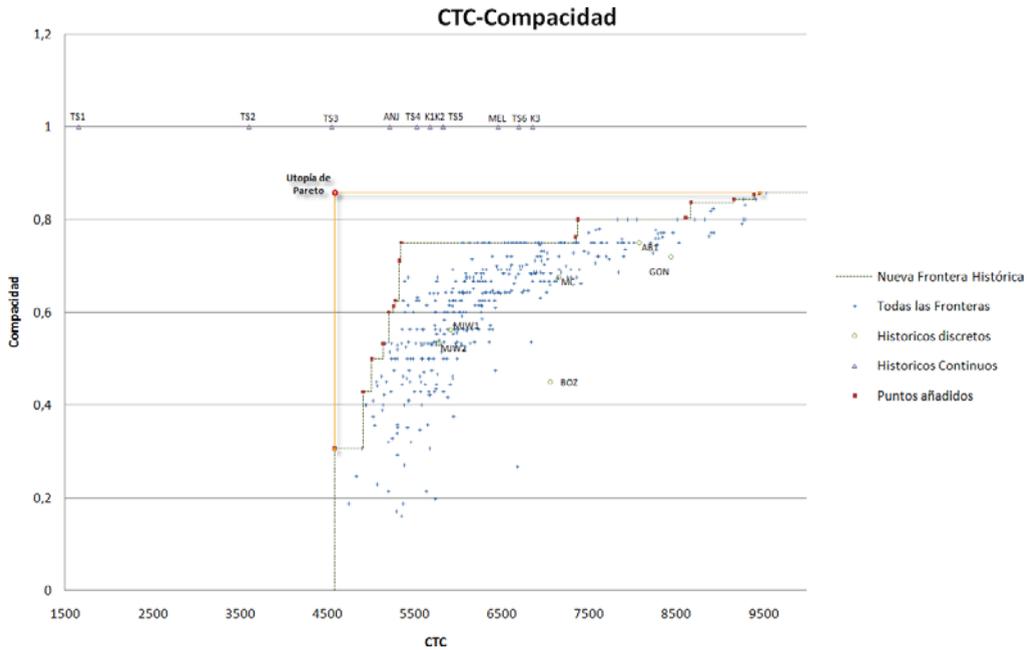


Figura 7.4.27 Nueva frontera de Pareto del bicriterio Coste-Compacidad Máxima.

Ninguno de los puntos de la frontera de Pareto obtenida es dominado por una solución histórica y además todas las soluciones históricas son dominadas por la frontera de Pareto obtenida.

Los puntos que definen la nueva frontera de Pareto para el bicriterio Coste-Compacidad son los mostrados en la siguiente tabla:

| Nº Sol | Código Solución | Coste | Comp. |
|--------|---|---------|-------|
| 1 | 1-16-11-17-12-20-6-7-8-18-2-4-19-3-10-14-9-15-13-5 6 2+3+3+3+3+16 | 5153,83 | 0,53 |
| 2 | 11-16-1-17-13-9-15-12-5-6-10-14-18-3-19-2-4-7-8-20 8 3+2+2+4+2+3+5+9 | 5337,15 | 0,71 |
| 3 | 11-16-1-13-17-9-15-12-5-6-10-14-18-3-19-2-4-7-8-20 8 3+2+2+4+2+3+5+9 | 5357,86 | 0,75 |
| 4 | 11-16-1-13-17-9-15-12-5-6-10-14-18-3-19-2-4-7-8-20 9 3+2+2+2+2+2+3+5+9 | 5214,66 | 0,6 |
| 5 | 1-17-15-12-6-3-9-19-4-2-7-8-20-11-18-16-13-14-10-5 6 3+2+3+9+7+6 | 7381,79 | 0,8 |
| 6 | 6-20-7-4-2-19-8-11-18-5-10-17-12-3-1-14-16-9-15-13 8 2+2+2+2+5+2+6+9 | 9168,63 | 0,84 |
| 7 | 11-16-17-15-13-9-14-10-3-12-1-18-2-4-19-8-7-20-6-5 7 2+2+2+2+2+11+9 | 5289,77 | 0,63 |
| 8 | 5-12-17-20-10-15-14-18-11-7-8-19-3-4-2-1-9-13-16-6 8 2+2+3+4+4+9+3+3 | 8618,42 | 0,8 |
| 9 | 13-18-11-12-15-14-9-17-20-10-8-19-3-4-2-1-7-5-16-6 8 2+2+3+4+4+9+3+3 | 9467,35 | 0,86 |
| 10 | 13-18-17-12-15-14-9-11-20-10-8-19-3-4-2-1-7-5-16-6 8 2+2+3+4+4+9+3+3 | 9400,93 | 0,85 |
| 11 | 1-18-16-11-17-15-6-4-13-14-9-19-7-8-2-3-5-12-20-10 10 2+3+3+5+2+4+2+3+4+2 | 7356,86 | 0,76 |
| 12 | 11-16-1-13-14-15-10-3-12-9-17-18-6-4-2-19-7-8-20-5 6 3+2+2+2+12+9 | 5270,8 | 0,61 |
| 13 | 11-16-13-17-12-15-5-10-14-1-6-3-19-4-7-9-2-8-20-18 6 2+2+2+3+18+3 | 4594,67 | 0,31 |
| 14 | 11-16-13-17-12-20-8-6-7-2-4-19-1-3-9-10-15-14-18-5 8 2+2+3+2+2+2+14+3 | 4920,28 | 0,43 |
| 15 | 18-16-11-13-20-8-3-7-6-14-4-2-10-9-19-12-17-1-5-15 7 2+2+2+2+2+18+2 | 5020,63 | 0,5 |
| 16 | 10-14-5-13-12-17-11-9-16-8-3-7-4-2-19-6-1-15-18-20 8 3+2+3+3+3+9+4+3 | 8678,93 | 0,84 |

Tabla 7.4.6 Soluciones aportadas a la frontera de Pareto Coste-Compacidad Máxima.

La solución de las aportadas más cercana a la utopía de Pareto es la 3, con un valor de coste de 5357.86 y una compacidad de 0.75 que se muestra en la siguiente figura:

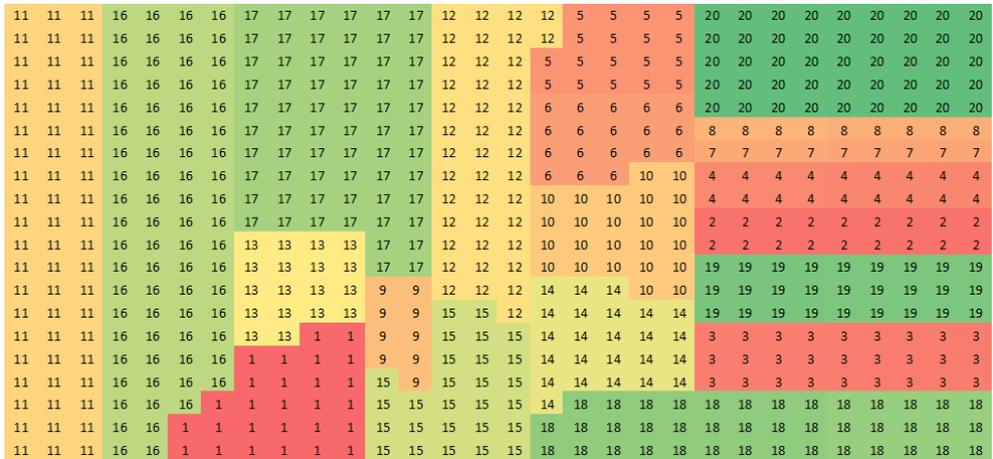


Figura 7.4.28 Solución aportada nº 3 a la frontera Coste-Compacidad Máxima.

La solución que alcanza un mayor valor de compacidad es la solución 9, con un valor de 0.86 y un coste de 9467.35.

| | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|
| 13 | 13 | 11 | 11 | 11 | 11 | 11 | 11 | 9 | 9 | 9 | 9 | 17 | 17 | 17 | 17 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 7 | 7 | 7 | 6 | 6 | 6 |
| 13 | 13 | 11 | 11 | 11 | 11 | 11 | 11 | 9 | 9 | 9 | 9 | 17 | 17 | 17 | 17 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 7 | 7 | 7 | 6 | 6 | 6 |
| 13 | 13 | 11 | 11 | 11 | 11 | 11 | 11 | 14 | 14 | 14 | 14 | 17 | 17 | 17 | 17 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 7 | 7 | 7 | 6 | 6 | 6 |
| 13 | 13 | 11 | 11 | 11 | 11 | 11 | 11 | 14 | 14 | 14 | 14 | 17 | 17 | 17 | 17 | 2 | 2 | 2 | 2 | 2 | 2 | 2 | 2 | 2 | 2 | 5 | 5 | 5 | 6 | 6 | 6 |
| 13 | 13 | 11 | 11 | 11 | 11 | 11 | 11 | 14 | 14 | 14 | 14 | 17 | 17 | 17 | 17 | 2 | 2 | 2 | 2 | 2 | 2 | 2 | 2 | 2 | 2 | 5 | 5 | 5 | 6 | 6 | 6 |
| 13 | 13 | 11 | 11 | 11 | 11 | 11 | 11 | 14 | 14 | 14 | 14 | 17 | 17 | 17 | 17 | 4 | 4 | 4 | 4 | 4 | 4 | 4 | 4 | 4 | 4 | 5 | 5 | 5 | 6 | 6 | 6 |
| 13 | 13 | 11 | 11 | 11 | 11 | 11 | 11 | 14 | 14 | 14 | 14 | 17 | 17 | 17 | 17 | 4 | 4 | 4 | 4 | 4 | 4 | 4 | 4 | 4 | 4 | 5 | 5 | 5 | 16 | 16 | 16 |
| 13 | 13 | 11 | 11 | 11 | 11 | 11 | 11 | 14 | 14 | 14 | 14 | 17 | 17 | 17 | 17 | 3 | 3 | 3 | 3 | 3 | 3 | 3 | 3 | 3 | 3 | 5 | 5 | 5 | 16 | 16 | 16 |
| 13 | 13 | 11 | 11 | 11 | 11 | 11 | 11 | 15 | 15 | 15 | 15 | 17 | 17 | 17 | 17 | 3 | 3 | 3 | 3 | 3 | 3 | 3 | 3 | 3 | 5 | 5 | 5 | 16 | 16 | 16 | |
| 18 | 18 | 11 | 11 | 11 | 11 | 11 | 11 | 15 | 15 | 15 | 15 | 17 | 17 | 17 | 17 | 3 | 3 | 3 | 3 | 3 | 3 | 3 | 3 | 3 | 5 | 16 | 16 | 16 | 16 | 16 | 16 |
| 18 | 18 | 11 | 18 | 11 | 11 | 11 | 11 | 15 | 15 | 15 | 15 | 17 | 17 | 17 | 17 | 19 | 19 | 19 | 19 | 19 | 19 | 19 | 19 | 19 | 16 | 16 | 16 | 16 | 16 | 16 | 16 |
| 18 | 18 | 18 | 18 | 11 | 11 | 11 | 11 | 15 | 15 | 15 | 15 | 17 | 17 | 17 | 17 | 19 | 19 | 19 | 19 | 19 | 19 | 19 | 19 | 19 | 16 | 16 | 16 | 16 | 16 | 16 | 16 |
| 18 | 18 | 18 | 18 | 11 | 11 | 11 | 11 | 15 | 15 | 15 | 15 | 17 | 17 | 17 | 17 | 19 | 19 | 19 | 19 | 19 | 19 | 19 | 19 | 19 | 16 | 16 | 16 | 16 | 16 | 16 | 16 |
| 18 | 18 | 18 | 18 | 12 | 12 | 12 | 12 | 15 | 15 | 15 | 15 | 17 | 17 | 17 | 17 | 8 | 8 | 8 | 8 | 8 | 8 | 8 | 8 | 8 | 16 | 16 | 16 | 16 | 16 | 16 | 16 |
| 18 | 18 | 18 | 18 | 12 | 12 | 12 | 12 | 15 | 15 | 15 | 15 | 17 | 17 | 17 | 17 | 10 | 10 | 10 | 10 | 10 | 10 | 10 | 10 | 10 | 16 | 16 | 16 | 16 | 16 | 16 | 16 |
| 18 | 18 | 18 | 18 | 12 | 12 | 12 | 12 | 12 | 12 | 12 | 12 | 17 | 17 | 17 | 17 | 10 | 10 | 10 | 10 | 10 | 10 | 10 | 10 | 10 | 16 | 16 | 16 | 16 | 16 | 16 | 16 |
| 18 | 18 | 18 | 18 | 12 | 12 | 12 | 12 | 12 | 12 | 12 | 12 | 20 | 20 | 20 | 17 | 10 | 10 | 10 | 10 | 10 | 10 | 10 | 10 | 20 | 16 | 16 | 16 | 16 | 16 | 16 | 16 |
| 18 | 18 | 18 | 18 | 12 | 12 | 12 | 12 | 12 | 12 | 12 | 12 | 20 | 20 | 20 | 20 | 20 | 20 | 20 | 20 | 20 | 20 | 20 | 20 | 20 | 16 | 16 | 16 | 16 | 16 | 16 | 16 |
| 18 | 18 | 18 | 18 | 12 | 12 | 12 | 12 | 12 | 12 | 12 | 12 | 20 | 20 | 20 | 20 | 20 | 20 | 20 | 20 | 20 | 20 | 20 | 20 | 20 | 16 | 16 | 16 | 16 | 16 | 16 | 16 |
| 18 | 18 | 18 | 18 | 12 | 12 | 12 | 12 | 12 | 12 | 12 | 12 | 20 | 20 | 20 | 20 | 20 | 20 | 20 | 20 | 20 | 20 | 20 | 20 | 20 | 16 | 16 | 16 | 16 | 16 | 16 | 16 |

Figura 7.4.29 Solución de la frontera Coste-Compacidad Máxima con mayor compacidad.

7.4.2 Obtención de Frontera de Pareto Coste-Circulación-Forma Media Ponderada

Otro de los objetivos de la presente investigación era implementar y testear el algoritmo MOSA para más de dos objetivos, empleando para cada uno de ellos una temperatura independiente.

En la bibliografía, tal y como se comentó en capítulos anteriores, se pueden encontrar algunas referencias que muestran resultados de optimizaciones bicriterio del problema bicriterio, pero no se encuentra ninguna que aborde el problema empleando tres o más objetivos.

Para cumplir este objetivo se establece un único ensayo con los tres objetivos de configuración principales comentados en apartados anteriores, como son el coste entre centroides, la forma media ponderada y el nuevo indicador de circulación, todos ellos aplicados sobre el problema test de Armour y Buffa de 20 actividades con los mismos parámetros de forma de recinto y espacio que en los bicriterios.

El problema fundamental que se encontró durante la realización de este experimento es la lentitud del algoritmo cuando tiene que lidiar con más de dos objetivos, necesitando para cada lanzamiento un promedio de 72 horas para la finalización del proceso, más del triple de tiempo que el promedio de cada lanzamiento bicriterio.

Se realizaron un total de 40 lanzamientos del algoritmo, deteniendo el experimento tras detectar dos lanzamientos consecutivos sin que se produjera la mejora de la frontera 3D del problema. La representación de los resultados del problema se realiza con el programa *Statistica*, y no se detallan cada una de las soluciones al ser el número de ellas excesivamente elevado. En las representaciones, para garantizar una buena visibilidad de los resultados, se ha empleado un valor de coste entre centroides normalizado, empleando para realizar esta normalización el valor más alto de coste de una solución que haya sido parte en algún momento de la frontera de Pareto (15200).

En la Figura 7.4.30 se muestran los resultados obtenidos en el experimento, en color rosa se marcan los puntos de aquellas soluciones que en algún momento han formado parte de la frontera (2351) y en azul los puntos de la frontera final obtenida, que está formada por 336 puntos.

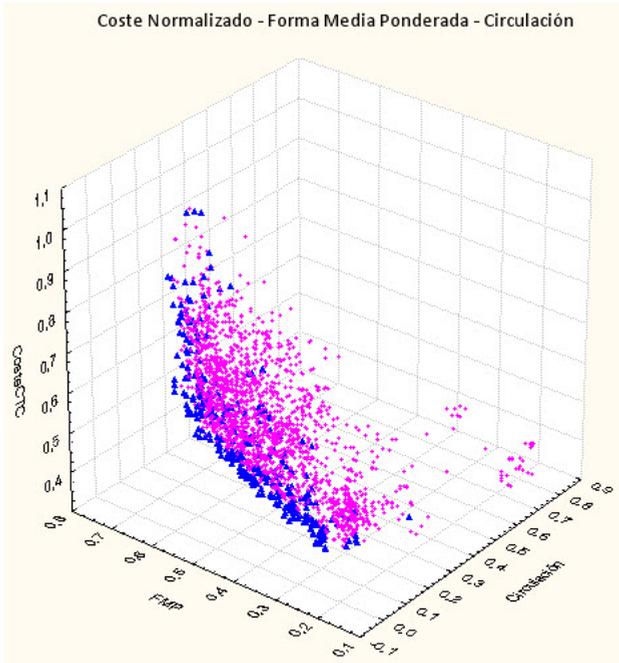


Figura 7.4.30 Frontera de Pareto CTC-Forma Media Ponderada-Circulación.

En la Figura 7.4.31 se puede observar la proyección de la frontera de Pareto obtenida en la optimización multiobjetivo sobre los planos Coste-Circulación (en granate) y Coste-Forma Media Ponderada (en negro).

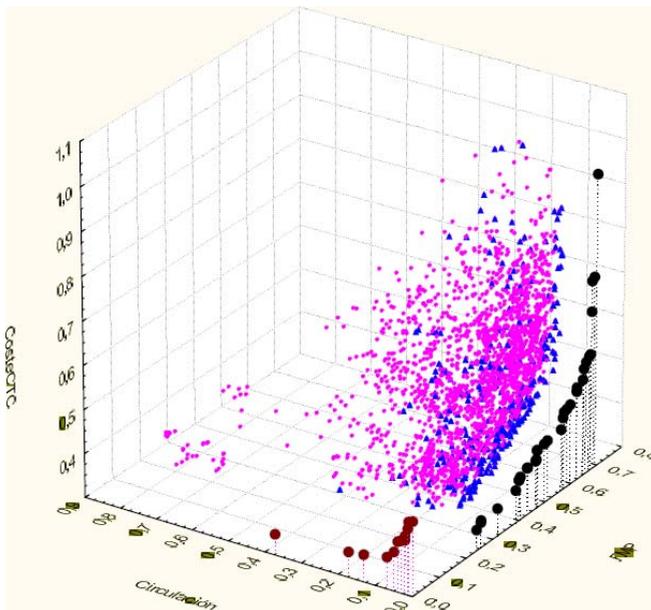


Figura 7.4.31 Proyección de la frontera de Pareto en bicriterios.

La proyección de la frontera 3D sobre el plano Coste-Circulación da lugar a las frontera bicriterio del problema, compuesta por 12 puntos, y cuya representación se muestra en la siguiente figura, en color verde.

En la misma figura, se representa también la frontera obtenida mediante la optimización bicriterio, que es mejor que la obtenida en el caso de la optimización con 3 objetivos, mediante una línea naranja.

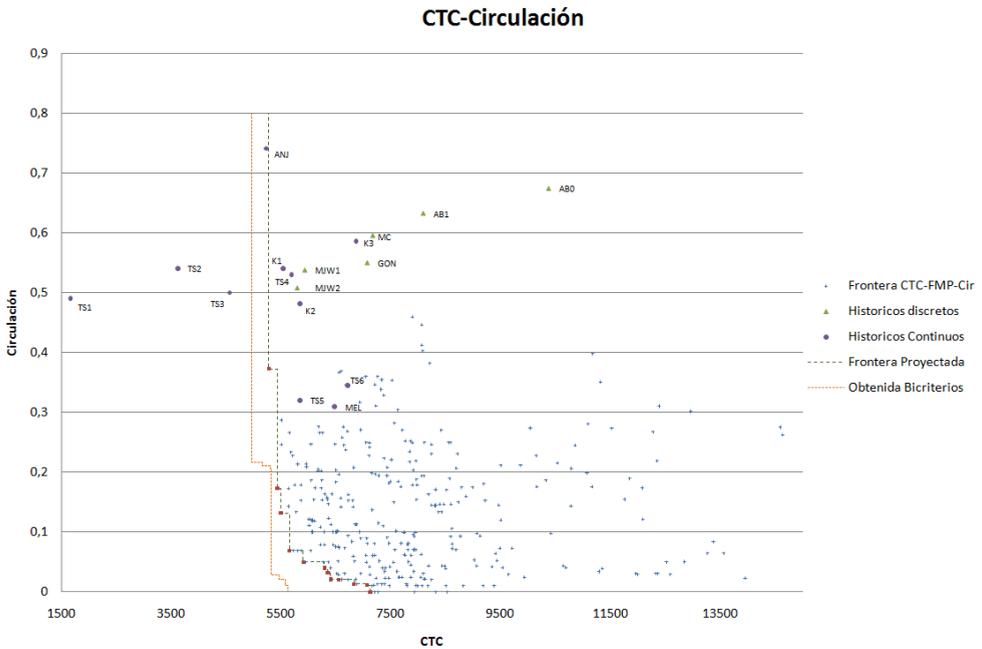


Figura 7.4.32 Proyección 2D y frontera bicriterio Coste-Circulación.

Por tanto la frontera obtenida en este punto es peor y ha requerido un mayor tiempo de proceso para ser obtenida, por tanto si el objetivo es determinar las fronteras bicriterio lo mejor es realizar una optimización de los criterios 2 a 2, más que realizar la optimización de tres objetivos.

De la misma forma se representa, en la Figura 7.4.33, la frontera obtenida mediante la proyección de la frontera 3D y la frontera obtenida con bicriterio para los indicadores Coste - Forma Media Ponderada.

La frontera proyectada Coste-FMP tiene un total de 32 puntos y también, al igual que en el caso de la anterior frontera los resultados obtenidos con la optimización con 3 objetivos son peores desde el punto de vista de los dos objetivos, siendo dominada por la obtenida en el experimento de optimización bicriterio.

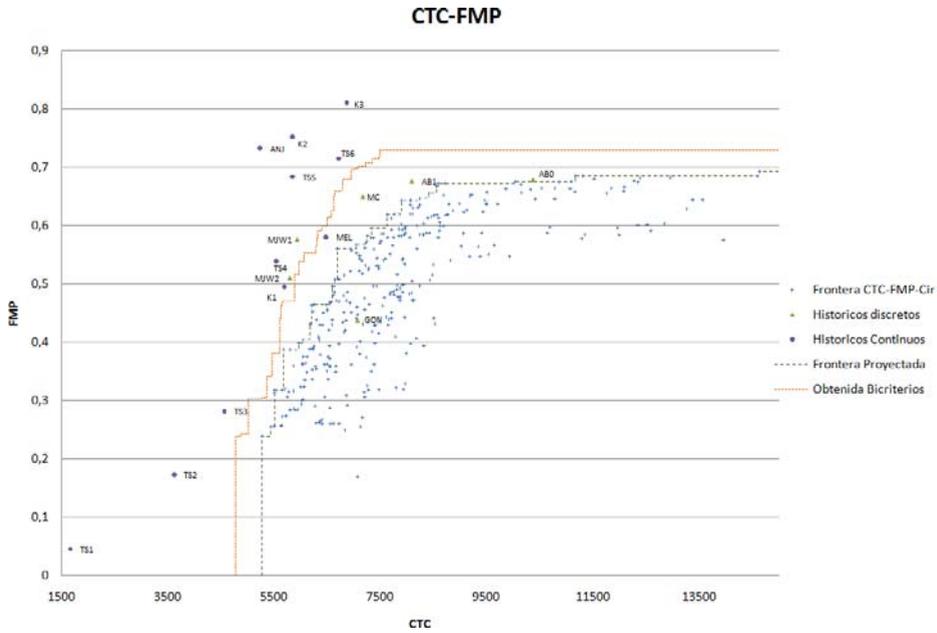


Figura 7.4.33 Proyección 2D y frontera bicriterio Coste-Forma Media Ponderada.

En cualquier caso, los datos obtenidos en la optimización con tres objetivos son valiosos pues nos proporcionan soluciones que son buenas atendiendo a los tres criterios estudiados, y que posteriormente pueden ser empleadas para obtener, mediante técnicas multicriterio, la solución más adecuada para el problema.

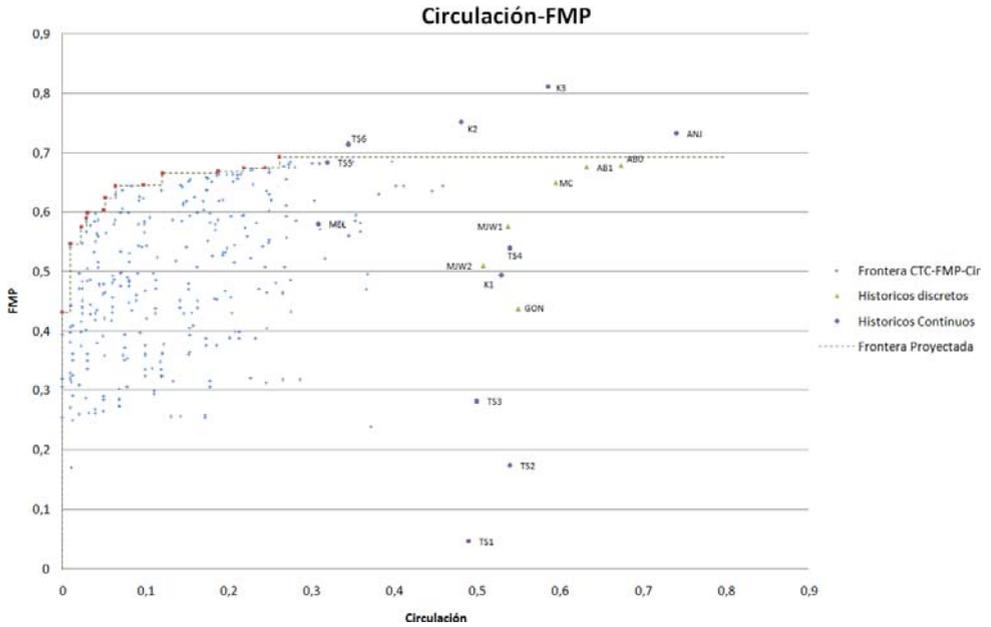


Figura 7.4.34 Proyección 2D y frontera bicriterio Circulación-Forma Media Ponderada.

| | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|
| 13 | 13 | 15 | 15 | 14 | 14 | 16 | 16 | 16 | 16 | 16 | 16 | 3 | 3 | 17 | 17 | 17 | 17 | 17 | 17 | 20 | 20 | 20 | 20 | 20 | 20 | 8 | 8 | 8 | 8 | |
| 13 | 13 | 15 | 15 | 15 | 14 | 16 | 16 | 16 | 16 | 16 | 16 | 3 | 3 | 17 | 17 | 17 | 17 | 17 | 17 | 20 | 20 | 20 | 20 | 20 | 20 | 8 | 8 | 8 | 8 | |
| 13 | 13 | 15 | 15 | 14 | 14 | 16 | 16 | 16 | 16 | 16 | 16 | 3 | 3 | 17 | 17 | 17 | 17 | 17 | 17 | 20 | 20 | 20 | 20 | 20 | 7 | 7 | 7 | 7 | 7 | 7 |
| 13 | 13 | 15 | 15 | 14 | 14 | 16 | 16 | 16 | 16 | 16 | 16 | 3 | 3 | 17 | 17 | 17 | 17 | 17 | 17 | 20 | 20 | 20 | 20 | 20 | 7 | 7 | 7 | 2 | 2 | 2 |
| 13 | 13 | 15 | 15 | 14 | 14 | 16 | 16 | 16 | 16 | 16 | 16 | 3 | 3 | 17 | 17 | 17 | 17 | 17 | 17 | 20 | 20 | 20 | 20 | 20 | 2 | 2 | 2 | 2 | 2 | 2 |
| 13 | 13 | 15 | 15 | 14 | 14 | 16 | 16 | 16 | 16 | 16 | 16 | 3 | 3 | 12 | 17 | 17 | 17 | 17 | 17 | 20 | 20 | 20 | 20 | 20 | 2 | 2 | 2 | 2 | 2 | 2 |
| 13 | 13 | 15 | 15 | 14 | 14 | 16 | 16 | 16 | 16 | 16 | 16 | 3 | 3 | 12 | 12 | 17 | 17 | 17 | 17 | 20 | 20 | 20 | 20 | 20 | 4 | 4 | 4 | 2 | 2 | 2 |
| 13 | 13 | 15 | 15 | 14 | 14 | 16 | 16 | 16 | 16 | 16 | 16 | 3 | 3 | 12 | 12 | 17 | 17 | 17 | 17 | 20 | 20 | 20 | 20 | 20 | 4 | 4 | 4 | 4 | 4 | 4 |
| 9 | 9 | 15 | 15 | 14 | 14 | 16 | 16 | 16 | 16 | 16 | 16 | 3 | 3 | 12 | 12 | 17 | 17 | 17 | 17 | 20 | 20 | 20 | 20 | 20 | 4 | 4 | 4 | 5 | 5 | 5 |
| 9 | 9 | 15 | 15 | 14 | 14 | 16 | 16 | 16 | 16 | 16 | 16 | 3 | 3 | 12 | 12 | 17 | 17 | 17 | 17 | 20 | 20 | 18 | 18 | 18 | 5 | 5 | 5 | 5 | 5 | 5 |
| 9 | 9 | 15 | 15 | 14 | 14 | 16 | 16 | 16 | 16 | 16 | 16 | 3 | 3 | 12 | 12 | 17 | 17 | 17 | 17 | 18 | 18 | 18 | 18 | 18 | 5 | 5 | 5 | 5 | 5 | 5 |
| 9 | 9 | 15 | 15 | 11 | 14 | 16 | 16 | 16 | 16 | 11 | 11 | 3 | 3 | 12 | 12 | 17 | 17 | 17 | 17 | 18 | 18 | 18 | 18 | 18 | 6 | 6 | 6 | 5 | 5 | 5 |
| 9 | 1 | 1 | 1 | 1 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 3 | 3 | 12 | 12 | 12 | 17 | 10 | 10 | 10 | 10 | 18 | 18 | 18 | 6 | 6 | 6 | 6 | 6 | 6 |
| 1 | 1 | 1 | 1 | 1 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 12 | 12 | 12 | 12 | 10 | 10 | 10 | 10 | 18 | 18 | 18 | 18 | 18 | 6 | 6 | 6 | 6 | 6 | 6 |
| 1 | 1 | 1 | 1 | 1 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 12 | 12 | 12 | 12 | 10 | 10 | 10 | 10 | 18 | 18 | 18 | 18 | 18 | 6 | 6 | 6 | 19 | 19 | 19 |
| 1 | 1 | 1 | 1 | 1 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 12 | 12 | 12 | 12 | 10 | 10 | 10 | 10 | 18 | 18 | 18 | 18 | 18 | 19 | 19 | 19 | 19 | 19 | 19 |
| 1 | 1 | 1 | 1 | 1 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 12 | 12 | 12 | 12 | 10 | 10 | 10 | 10 | 18 | 18 | 18 | 18 | 18 | 19 | 19 | 19 | 19 | 19 | 19 |
| 1 | 1 | 1 | 1 | 1 | 11 | 11 | 11 | 11 | 11 | 11 | 11 | 12 | 12 | 12 | 12 | 10 | 18 | 18 | 18 | 18 | 18 | 18 | 18 | 18 | 19 | 19 | 19 | 19 | 19 | 19 |

Figura 7.4.35 Solución con circulación nula.

8 CONCLUSIONES Y TRABAJO FUTURO

8.1 CONCLUSIONES

Con la fase experimental, en la que se han realizado pruebas con el generador de soluciones y la metaheurística de optimización multiobjetivo basada en algoritmos Simulated Annealing finaliza el trabajo de la presente tesis doctoral, cuyas conclusiones se pueden resumir brevemente en los siguientes puntos:

- Se ha realizado un estado del arte en lo relativo a los indicadores aplicados al problema de distribución planta desde su aparición (en los años 50) hasta la actualidad, clasificando los mismos atendiendo a diferentes criterios. Este trabajo ha dejado patente que el problema con el que se está tratando tiene un marcado carácter multiobjetivo y que son numerosos los autores que lo han tratado como tal.

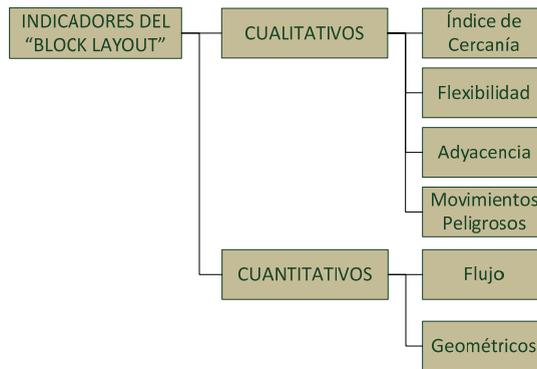


Figura 8.1.1 Esquema de indicadores del "block layout"

- Se ha establecido una relación directa entre los indicadores del problema con los principios básicos introducidos por Muther y los objetivos de la distribución en planta fijados por el mismo autor en las bases del SLP. Asimismo se ha realizado una selección de los indicadores más relevantes, eliminado aquellos que puedan resultar redundantes.

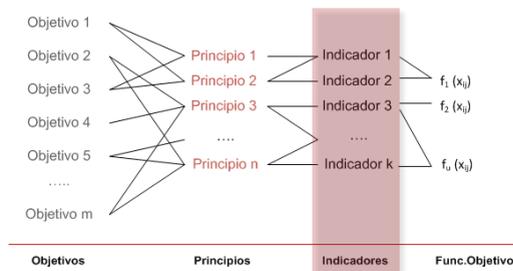


Figura 8.1.2 Relación Objetivos-Principios-Indicadores.

- Se ha propuesto un nuevo indicador, la circulación, que plasma directamente lo fijado en el principio de Circulación de Muther, reducir el tráfico de materiales en los pasillos. La formulación del indicador posibilita su empleo tanto en geometrías discretas como continuas, permite reducir (incluso a cero) el movimiento de materiales por los pasillos.

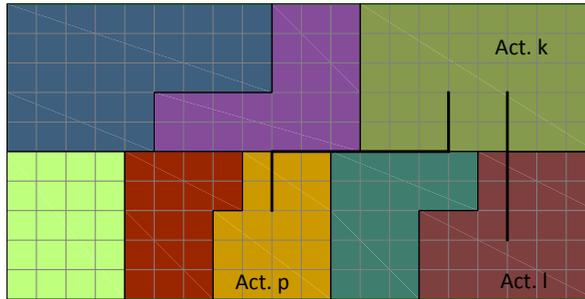


Figura 8.1.3 Indicador de circulación propuesto.

$$\tau = \frac{\sum_{i=1}^n \sum_{j=1}^n (1 - b_{ij}) \cdot f_{ij}}{\sum_{i=1}^n \sum_{j=1}^n f_{ij}} \quad (8.1)$$

- Se ha introducido, en el proceso de investigación, el empleo de métricas diferentes a las euclídeas (tipo EDIST). Aunque los resultados no pueden ser contrastados, pues es una métrica poco extendida, y al realizar la optimización multiobjetivo, considerando un indicador de forma, pierde sentido su empleo.

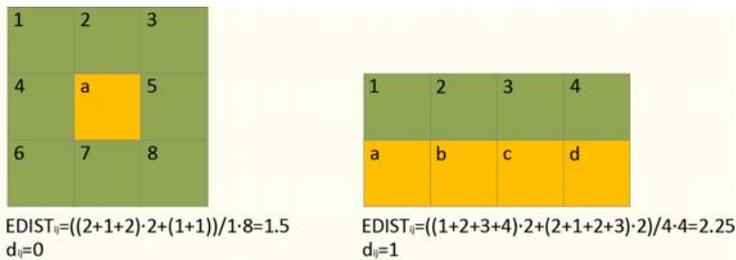


Figura 8.1.4 Ejemplo de cálculo de métrica EDIST.

- Se ha adaptado una metaheurística de optimización como es el MOSA (optimización multiobjetivo mediante recocido simulado) al problema de distribución en planta, trabajando con el concepto de frontera de Pareto. Una de la modificaciones realizadas es el empleo de tantas temperaturas como objetivos se estén manejando en la optimización. Esta metaheurística se ha mostrado eficiente, pues introduce nuevos puntos en las fronteras de Pareto históricas obtenidas de la bibliografía.

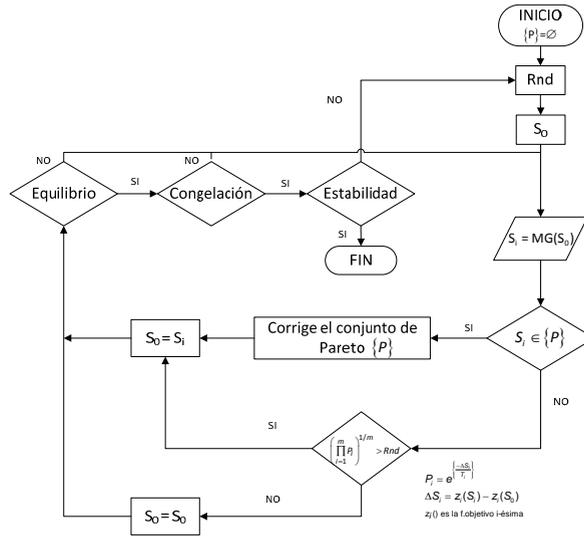


Figura 8.1.5 Esquema de funcionamiento del algoritmo propuesto.

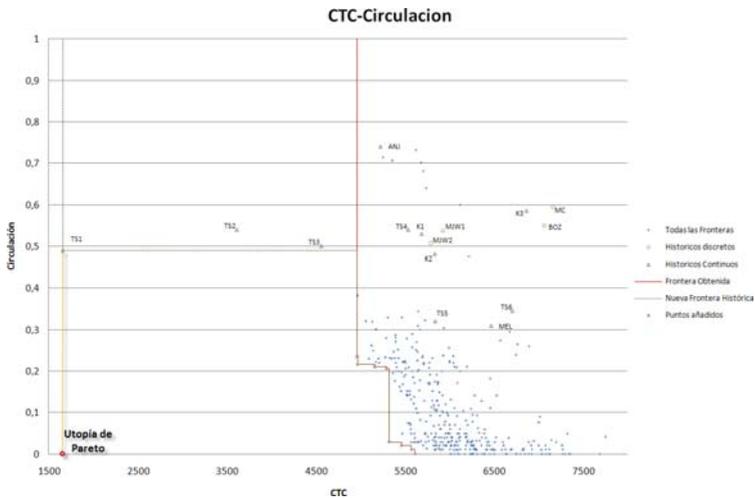


Figura 8.1.6 Una de las fronteras de Pareto obtenidas.

- Se ha experimentado con la posibilidad de efectuar optimizaciones con más de dos objetivos, sin que se hayan obtenido resultados que mejoren las fronteras bicriterio obtenidas. Otro problema detectado es el excesivo tiempo de cálculo empleado para obtener fronteras de Pareto en cada lanzamiento, debido al gran número de datos manejados. No obstante, las soluciones obtenidas con este enfoque permiten realizar un control de forma de las actividades mucho más adecuado.

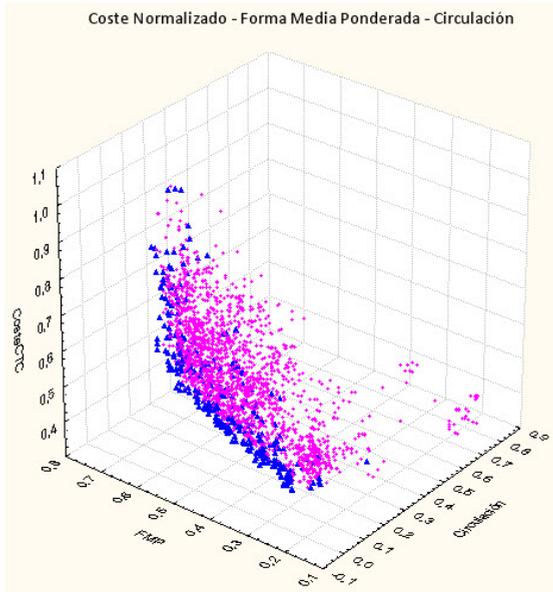


Figura 8.1.7 Frontera de Pareto 3D obtenida.

8.2 TRABAJOS FUTUROS

A lo largo del desarrollo de la presente tesis se han tomado decisiones sobre determinados aspectos que han dejado de lado algunos posibles caminos para ampliar el campo de la investigación y que es posible que en un futuro próximo se puedan desarrollar, bien por parte del autor o por algunos futuros doctorandos. Las posibles líneas de investigación en este campo son las siguientes:

- Realizar la optimización multiobjetivo de la distribución en planta de procesos industriales mediante el empleo de metaheurísticas poblacionales, contrastando los resultados con los obtenidos en este trabajo y consolidando el indicador de circulación propuesto.
- Reducir el tiempo de cálculo empleado para cada uno de los lanzamientos del algoritmo de optimización mediante la implementación de un sistema de memoria, para hacer al algoritmo capaz de recordar la mejor frontera de Pareto y así agilizar el proceso de optimización.
- Profundizar en la generación de curvas de relleno (SFC) más complejas, que añadan un mayor grado de libertad a la hora de realizar la construcción de soluciones, aunque ello conlleve un cambio significativo en la forma de generar la vecindad de una solución.
- Investigar en el desarrollo de indicadores independientes del tamaño de la actividad para aplicarlos al control formal de actividades.
- Introducir la forma del recinto como una variable más del proceso de optimización, pues es posible que en algunos casos (siempre que la estructura del problema lo permita) se puedan conseguir mejores resultados que con el recinto fijo.
- Ampliar el trabajo realizado al problema de distribución en planta en dos dimensiones y media (problema *multifloor*), utilizando curvas de relleno como las empleadas en el caso 2D y un modelo geométrico discreto.
- Integrar el cálculo estructural en todo el proceso de optimización para el caso del problema *multifloor*, introduciendo el coste de construcción, así como el coste medioambiental de la misma en el proceso.
- Utilizar las metaheurísticas de optimización multiobjetivo en otros campos de la ingeniería de la construcción afines al perfil profesional del autor, como en la optimización de elementos estructurales (cimentaciones, losas alveolares...) pues se ha mostrado la capacidad de mejora de soluciones que muestran.
- Aplicar la metodología establecida a otros problemas clásicos de la bibliografía como los de (Tompkins y White 1984) o (Francis y White 1974), con actividades fijas o recintos irregulares.

9 BIBLIOGRAFÍA

ABASS, H.A.

2001 «A Memetic Pareto Evolutionary Approach to Artificial Neural Networks», en *Lecture Notes in Artificial Intelligence*, vol. 2256, pp. 1-12. Adelaide, Australia: Springer.

ABDINNOUR-HELM, S. y S.W. HADLEY

1995 «An iterative layout heuristic for multifloor facilities». *Decision Science Institute Proceedings*. Boston, MA.

2000 «Tabu search based heuristics for multi-floor facility layout». *International Journal of Production Research* 38 (2): 365-383.

ADAM, E.E. y R.J. EBERT

1991 *Production and operations management, concepts, models and behavior*. Prentice Hall college div.

ADENSO-DÍAZ, B., F. GLOVER, H. GHAZIRI, J.M. GONZALEZ, M. LAGUNA, P. MOSCATO y F. TSENG

1996 *Optimización Heurística y redes neuronales en dirección de operaciones e ingeniería*. Madrid: Paraninfo.

AFENTAKIS, P.

1985 *A model for layout design in FMS*. New York: Dep. of industrial engineering and operations research. University, Syracuse.

AFRAZEH, A., A. KEIVANI y L. NAJAFABADI FARAHANI

2010 «A new model for dynamic multi floor facility layout problem». *Advanced Modeling and Optimization*, 12 (2): 249-256.

AIELLO, G., M. ENEA y G. GALANTE

2006 «A multi-objective approach to facility layout problem by genetic search algorithm and Electre method». *Robotics and Computer-Integrated Manufacturing* 22: 447-455.

ANJOS, M.F. y A. VANELLI

2002 «An attractor-repeller approach to floorplanning». *Mathematical methods of operations research* 56: 3-27.

2006 «A New Mathematical-Programming Framework for Facility-Layout Design». *Inform's Journal on computing* 18: 111-118.

APPLE, J.M.

1968 *Plant layout and material handling*. Krieger Pub Co.

APPLE, J.M. y M.P. DEISENROTH

1972 «A computerized plant layout analysis and evaluation technique (PLANET)». *A.I.I.E. Technical papers, 23rd conference* 121-127. Anaheim, California.

ARMOUR, GC y ES BUFFA

1963 «A heuristic algorithm and simulation approach to the relative location of facilities». *Management Science* 9: 294-309.

BADIRU, A.B. y A. ARIF

1996 «FLEXPERT: Facility Layout EXPert system using fuzzy linguistic relationship codes». *IIE Transactions* 28: 295-308.

BANDYOPADHYAY, S., S. SAHA, U. MAULIK y K. DEB

2008 «A simulated annealing-based multiobjective optimization algorithm (AMOS)». *IEEE Transactions on evolutionary computation* 12 (3): 269-283.

BANERJEE, P., B. MONTREUIL, C.L. MOODIE y R.L. KASHYAP

1992 «A modelling of interactive facilities layout designer reasoning using qualitative patterns». *International Journal of Production Research* 30 (2): 433-453.

BARBOSA-PÓVOA, A.P., R. MATEUS y A.Q. NOVAIS

2001 «Optimal 2D Layout Design of Industrial Facilities». *International Journal of production research* 39 (12): 2567-2593.

2002 «Optimal 3D layout of industrial facilities». *International Journal of production research* 40 (7): 1669-1698.

BARTHOLDI III, J.J. y L.K. PLATZMAN

1982 «An $O(N \log N)$ planar travelling salesman heuristic based on Spacefilling curves». *Operations Research Letters* 1 (4): 121-124.

BAZARAA, M.S.

1975 «Computerised layout design: a branch and bound approach». *IIE Transactions* 7 (4): 432-438.

BEAUSOLEIL, R.P.

2006 «"MOSS" multiobjective scatter search applied to non-linear multiple criteria optimization». *European Journal of Operational Research* 169 (2): 426-449.

BENSON, B. y B.L. FOOTE

1997 «DoorFAST: A constructive procedure to optimally layout a facility including aisles and door locations based don an aisle flow distance metric». *International Journal of production research* 35 (7): 1825-1842.

BLOCK, T.E.

1979 «On the complexity of facilities layout problems». *Management Science* 25 (3): 280-285.

BLUM, C. y A. ROLI

2003 «Metaheuristics in combinatorial optimization: Overview and conceptual design». *ACM Computing surveys* 3: 268-308.

BOSWELL, S.G.

1992 «TESSA-A new greedy heuristic for facilities layout planning». *International Journal of production research* 30 (8): 1957-1968.

BOZER, Y.A. y R.D. MELLER

1997 «A reexamination of the distance based facility layout problem». *IIE Transactions* 29: 549-560.

BOZER, Y.A., R.D. MELLER y S.J. ERLEBACHER

1994 «An Improvement-type layout algorithm for single and multiple-floor facilities». *Management Science* 40 (7): 918-932.

BUFFA, E.S.

1955 «Sequence analysis for functional layouts». *The journal of industrial engineering* VI (2): 12-25.

CAMBRON, K.E. y G.W. EVANS

1991 «Layout design using the Analytic Hierarchy Process». *Computers & industrial engineering* 20 (2): 211-229.

CAMERON, D.C.

1952 «Travel Charts». *Modern Material Handling* 37-40.

CARRIE, A.S., J.M. MOORE, M. ROCZNIK y J.J. SÉPPANEN

1978 «Graph theory and computer aided facilities design». *Omega* 6 (8): 353-361.

CHANG, C., J. LIN y H. LIN

2006 «Multiple-Floor Facility Layout Design with aisle construction». *IEMS* 5 (1): 1-10.

CHARNES, A. y W.W. COOPER

1961 *Management Models and industrial applications of linear programming vol.1*. New York: John Wiley and Sons.

CHATERJEE, A., M. COHEN, W. MAXWELL y L. MILLER

1984 «Manufacturing flexibility: Models and measurements». En , Ann Arbor.

CHEN, C.W. y D.Y. SHA

1999 «A design approach to the multi-objective facility layout problem». *International journal of production research* 37 (5): 1175-1196.

2005 «Heuristic approach for solving the multi-objective facility layout problem». *International journal of production research* 21 (1): 4493-4507.

CHEN, Y.K., S.W. LIN y S.Y. CHOU

2002 «An efficient two-staged approach for generating block layouts». *Computers and operations research* 29: 489-504.

COELHO, G.P. y F. VON ZUBEN

2006 «Omni-aiNet: An immune-inspired approach for omni optimization». En , Oeiras, Portugal.

COELLO COELLO, C.A.

1998 *Optimización Evolutiva con Objetivos Múltiples: Estado del Arte y Tendencias Futuras*, Francisco Cantú Ortiz y Alvaro de Albornoz Bueno, eds. México D.F.: Centro de Investigación en Computación.

1999 «A Comprehensive Survey of Evolutionary-Based Multiobjective Optimization Techniques». *Knowledge and information systems* 1: 269-308.

2006 «Evolutionary Multiobjective Optimization: A Historical View of the Field». *IEEE Computational Intelligence Magazine* 1 (1): 28-36.

2009 «Evolutionary multi-objective optimization: some current research trends and topics that remain to be explored». *Frontiers of Computer Science in China* 3 (1): 18-30.

COELLO COELLO, C.A. y N. CRUZ CORTÉS

2005 «Solving Multiobjective Optimization Problems using an Artificial Immune System». *Genetic Programming and Evolvable Machine* 6 (2): 163-290.

COELLO COELLO, C.A. y G. TOSCANO

2001 «A Micro-Genetic Algorithm for Multiobjective Optimization.», en *First International Conference on Evolutionary Multi-Criterion Optimization*, Kalyanmoy Deb, Lothar Thiele, Carlos A. Coello Coello and David Corne Eckart Zitzler, ed., vol. Lecture Notes in Computer Science No. 1993, pp. 126-140. Springer-Verlag.

COLORNI, A., M. DORIGO y V. MANIEZZO

1992 «Distributed optimization by Ant Colonies», en *Proceedings of the First European Conference on Artificial Life*, F.Varela and P.Bourgine, ed., pp. 509-520. Elsevier Publishing.

CONTERO GONZALEZ, M.

1995 *Aportación a la optimización del diseño geométrico de plantas industriales. Distribución en planta*. Tesis Doctoral. Universidad Politécnica de Valencia.

CORNE, D.W, N.R. JERRAM y J.D. KNOWLES

2001 «PESA-II: Region-based Selection in Evolutionary Multiobjective Optimization», en *Proceedings of the Genetic and Evolutionary Computation Conference (GECCO-2001)*, pp. 283-290. San Francisco, California: Morgan Kaufmann Publishers.

CORNE, D.W., J.D. KNOWLES y M.J. OATES

2000 «The Pareto Envelope-based Selection Algorithm for Multiobjective Optimization», en *Proceedings of the Parallel Problem Solving from Nature VI Conference*, pp. 839-848. Springer.

CZYZAK, P. y A. JASZKIEWICZ

1996 «A multiobjective metaheuristic approach to the localization of a chain of petrol stations by the capital budgeting model». *Control and Cybernetics* 25 (1): 177-187.

1997a «The Multiobjective Metaheuristic Approach for Optimization of Complex Manufacturing Systems», en *Multiple Criteria Decision Making. Proceedings of the XIIth International Conference*, G. Fandel and T. Gal, ed., pp. 591-592. Hagen, Germany: Springer-Verlag.

1997b «Pareto Simulated Annealing», en *Multiple Criteria Decision Making. Proceedings of the XIIth International Conference*, G. Fandel and T. Gal, ed., pp. 297-307. Hagen, Germany: Springer-Verlag.

1998 «Pareto simulated annealing-a metaheuristic technique for multiple-objective combinatorial optimization». *Journal of Multi-Criteria Decision Analysis* 7: 34-47.

DAS, S.K.

1993 «A facility layout method for flexible manufacturing systems». *International journal of production research* 31 (2): 279-297.

DAWKINS, R.

1986 *El gen egoista: las bases biológicas de nuestra conducta*. Barcelona: Salvat.

DEB, K., S. AGRAWAL, A. PRATAB y T. MEYARIVAN

2000 «A Fast Elitist Non-Dominated Sorting Genetic Algorithm for Multi-Objective Optimization: NSGA-II». Indian Institute of Technology, KanGAL report 200001. Kanpur, India.

DEB, S.K. y B. BHATTACHARYYA

2003 «Facilities layout planning based on fuzzy multiple criteria decision-making methodology». *International journal of production research* 18 (4487-4504): 41.

DIEGO-MÁS, J.A.

2006 *Optimización de la distribución en planta de instalaciones industriales mediante algoritmos genéticos. Aportación al control de la geometría de las actividades*. Tesis Doctoral. Universidad Politécnica de Valencia.

DONAGHEY, C.E. y V.F. PIRE

1990 «Solving the facility layout problem with BLOCPLAN». University of Houston, Industrial Engineering Department. Houston, TX.

DORIGO, M.

1992 *Ottimizzazione, apprendimento automatico, ed algoritmi basati su metafora naturale*. Tesis doctoral. Politecnico di Milano.

DOWLATSHAHI, S.

1994 «A modelling approach to design of integrated facilities». *International Journal of Production Research* 32 (6): 1313-1330.

DOWSLAND, K.A. y B. ADENSO DIAZ

2003 «Heuristic design and fundamentals of the simulated annealing». *Inteligencia Artificial, revista iberoamericana de inteligencia artificial* 19: 93-102.

DREZNER, Z.

1980 «DISCON: A new method for the layout problem». *Operations Research* 28 (6): 1375-1394.

DRIRA, A., H. PIERREVAL y S. HAJRI-GABOUJ

2007 «Facility layout problems: A survey». *Annual reviews in control* 31: 255-267.

DUARTE, N.M., A.E. RUANO, C.M. FONSECA y P.J. FLEMING

2000 «Accelerating Multi-Objective Control System Design Using a Neuro-Genetic Approach», en *2000 Congress on Evolutionary Computation*, vol. 1, pp. 392-397. Piscataway, New Jersey: IEEE Service Center.

DUCHEYNE, E.I., R. DE WULF y B. DE BAETS

2001 «Bi-objective genetic algorithm for forest management: a comparative study». *Proceedings of the 2001 Genetic and Evolutionary Computation Conference. Late-Breaking Papers* 63-66. San Francisco, California.

DUTTA, K.N. y S. SAHU

1982 «A multigoal heuristic for facilities design problems: MUGHAL». *International journal of production research* 20 (2): 147-154.

1983 «Comments on "A note on multigoal heuristic for facilities design problems:MUGHAL"». *International Journal of production research* 21 (3): 441-42.

DWEIRI, F y FA MEIER

1996 «Application of fuzzy decision making in facilities layout planning». *International Journal of production research* 34: 3207-3226.

ENGRAND, P.

1997 «A multi-objective optimization approach based on simulated annealing and its application to nuclear fuel management», en *Proceedings of the Fifth International Conference on Nuclear Engineering*, pp. 416-423. Nice, France: American Society of Mechanical Engineering.

ERICKSON, M., A. MAYER y J. HORN

2002 «Multi-objective optimal design of groundwater remediation systems: application of the niched Pareto genetic algorithm (NPGA)». *Advances in Water Resources* 25 (1): 51-65.

FONSECA, C.M. y P.J. FLEMING

1993 «Genetic Algorithms for Multiobjective Optimization: Formulation, Discussion and Generalization», edición de Stephanie Forrest. *Proceedings of fifth International conference on Genetic Algorithms* 416-423. San Mateo - California.

1995 «An Overview of evolutionary algorithms in multiobjective optimization». *Evolutionary Computation* 3 (1): 1-16.

FORTENBERRY, J.C. y J.F. COX

1985 «Multiple criteria approach to the facilities layout problem». *International journal of production research* 23 (4): 773-782.

FOULDS, L.R. y D.F. ROBINSON

1976 «A strategy for solving the plant layout problem». *Operational Research Quarterly* 27 (4): 845-855.

1978 «Graph theoretic heuristic for the plant layout problem». *International Journal of production research* 16 (1): 27-37.

FRANCIS, R.L. y J.A. WHITE

1974 *Facility Layout and Location, an analytical approach*, 1 vols. Prentice-Hall.

FREEMAN, H.

1974 «Computer Processing of Line-Drawing Images». *Computing Surveys* 6: 57-97.

FRESCHI, F. y C.A. COELLO COELLO

2009 «Multiobjective Optimization and Artificial Immune Systems: A Review», en *Handbook of Research on Artificial Immune Systems and Natural Computing: Applying Complex Adaptive Technologies*, pp. 1-21. Hershey, New York: Medical Information Science Reference.

GARCIA-MARTINEZ, C., O. CORDÓN y F. HERRERA

2004 «A taxonomy and a empirical analysis of multiple objective ant colony optimization algorithms for the bi-criteria TSP». Univ. Granada, Dept of computer science and artificial intelligence. Granada, Spain.

GEORGIADIS, M.C., G. SCHILLING, G.E. ROTSEIN y S. MACCHIETTO

1999 «A general mathematical programming approach for process plant layout». *Computers and Chemical Engineering* 23: 823-840.

GILMORE, P.C.

1962 «Optimal and suboptimal algorithms for the quadratic assignment problem». *J.Soc. Appl. Math.* 10 (2): 305-362.

GLOVER, F.

1986 «Future paths for integer programming and links to artificial intelligence». *Computers and operations research* 5: 533-549.

GOLDBERG, D.E.

1989 *Genetic Algorithms in search, optimization and machine learning*. Reading, Massachussets: Addison-Wesley Publishing Company.

GOMORY, R.E.

1958 «Outline of an algorithm for integer solutions to linear programming». *Bulletin of the american mathematical programming* 275-278.

GONZALEZ, J.L.

2005 *Aportación a la optimización multiobjetivo del diseño de plantas industriales*. Tesis Doctoral. Universidad Politécnica de Valencia.

GREEN, R.H. y L. AL-HAKIM

1985 «A heuristic for facilities layout planning». *Omega* 13 (5): 469-475.

GUNTSCH, M. y M. MIDDENDORF

2003 «Solving Multi-criteria Optimization Problems with Population-Based ACO», en *Evolutionary Multi-Criterion Optimization. Second International Conference, EMO 2003*, Peter J. Fleming, Eckart Zitzler, Kalyanmoy Deb and Lothar Thiele Carlos M. Fonseca, ed., vol. 2632, pp. 464-478. Faro, Portugal: Springer. Lecture Notes in Computer Science.

HAIDINE, A. y R. LEHNERT

2008 «Multi-Case Multi-Objective Simulated Annealing (MC-MOSA): New Approach to adapt simulated annealing to multiobjective optimization». *International Journal of information Technology* 4 (3): 197-205.

HARMONOSKY, C.M. y G.K. TOTHERO

1992 «A multi-factor plant layout methodology». *International journal of production research* 30 (8): 1773-1789.

HASSAN, M.M.D. y G.L. HOGG

1989 «On converting a dual graph into a block layout». *International Journal of production research* 27 (7): 1149-1160.

1991 «On constructing a block layout by graph theory». *International Journal of production research* 29 (6): 1263-1278.

HERAGU, S.S.

1997 *Facilities Design*. International Thomson Publishing Company.

HERAGU, S.S. y A. KUSIAK

1991 «Efficient models for the facility layout problem». *European Journal of Operational Research* 53 (1): 1-13.

1992 «Recent models and techniques for solving the layout problem». *European journal of operational research* 57 (2): 136-144.

HERNÁNDEZ-DÍAZ, A.G., L.V. SANTANA-QUINTERO, C.A. COELLO COELLO, R. CABALLERO y J. MOLINA

2006 «A New Proposal for Multi-Objective Optimization using Differential Evolution and Rough Sets Theory», en *2006 Genetic and Evolutionary Computation Conference (GECCO'2006)*, Maarten Keijzer et al., ed., vol. 1, pp. 675-682. Seattle, Washington: ACM Press.

HILLIER, F.S.

1963 «Quantitative tools for plant layout analysis». *The Journal of Industrial Engineering* 14 (1): 33-40.

HILLIER, F.S. y M.M. CONNORS

1966 «Quadratic Assignment Problem algorithms and the location of indivisible facilities». *Management Science* 13 (1): 42-57.

HORN, J., N. NAFPLIOTIS y D.E. GOLDBERG

1994 «A Niche Pareto Genetic Algorithm for Multiobjective Optimization», edición de IEEE Service Center. *Proceedings of the First IEEE Conference on Evolutionary Computation, IEEE World Congress on Computational Intelligence*, 1: 82-87. Piscataway, New Jersey.

HOSPITALER, A. y S. GRAU

1988 *Métodos analíticos de generación de layouts*. Valencia: Servicio de publicaciones UPV.

HOUSHYAR, A.

1991 «Computer aided facility layout: an interactive multi-goal approach». *Computers & industrial engineering* 20 (2): 177-186.

HWANG, CL y KP YOON

1981 *Multiple attribute decision making: methods and applications*. New York: Springer.

IMMER, J.R.

1950 *Layout Planning Techniques*. New York: McGraw Hill.

IORIO, A.W. y X. LI

2004 «Solving rotated multi-objective optimization problems using differential evolution». *AI 2004: Advances in Artificial Intelligence, Proceedings* 3339: 861-872.

ISHIBUCHI, H. y T. MURATA

1996 «Multi-Objective Genetic Local Search Algorithm». *Proceedings of the 1996 International Conference on Evolutionary Computation* 119-124. Nagoya, Japan.

ISLIER, A.A.

1998 «A genetic algorithm for multiple criteria facility layout design». *International journal of production research* 36 (6): 1549-1569.

JASZKIEWICZ, A.

1998 «Genetic Local Search for Multiple Objective Combinatorial Optimization». *Technical Report RA-014/98. Institute of Computing Science, Poznan University of Technology*.

JOHNSON, R.V.

1982 «SPACECRAFT for multi-floor layout planning». *Management Science* 28 (4): 407-417.

KAKU, B.K., G.L. THOMSON y I. BAYBARS

1988 «A heuristic method for the multi-storey layout problem». *European Journal of Operational Research* 37: 384-397.

KENNEDY, J. y R.S. EBERHART

1995 «Particle Swarm Optimization». *Proceedings of the 1995th IEEE International Conference on Neural Networks* 1942-1948.

KHALIL, T.M.

1973 «Facilities relative allocation technique (FRAT)». *International Journal of production research* 11 (2): 183-194.

KHARE, V.K., M.K. KHARE y M.L. NEEMA

1988 «Combined computer-aided approach for the facilities design problem and estimation of the distribution parameter in the case of multigoal optimization». *Computers and industrial engineering* 14 (4): 465-476.

KHILWANI, N., R. SHANKAR y M.K. TIWARI

2008 «Facility layout problem:an approach based on a group decision-making system and pchoclonal algorithm». *International Journal of Production Research* 46 (4): 895-927.

KIM, J.G. y M. GOETSCHALCKX

2005 «An integrated approach for the concurrent determination of the block layout and the input and output point locations based on the contour distance». *International Journal of production research* 43 (10): 2027-2047.

KIM, J.G. y Y.D. KIM

1998 «A space partitioning method for facility layout problems with shape constraints». *IIE Transactions* 30 (10): 947-957.

KIRKPATRICK, S., C.D. GELATT y M.P. VECCHI

1983 «Optimization by simulated annealing». *Science* 220 (4598): 671-680.

KNOWLES, J. y D. CORNE

1999 «The Pareto Archived Evolution Strategy: A New Baseline Algorithm for Multiobjective Optimisation», en *Congress on Evolutionary Computation*, vol. July, pp. 98-105. Washington, D.C: IEEE Service Center.

2000 «M-PAES: A Memetic Algorithm for Multiobjective Optimization», en *2000 Congress on Evolutionary Computation*, vol. 1, pp. 325-332. Piscataway, New Jersey: IEEE Service Center.

2004 «Memetic Algorithms for Multiobjective Optimization: Issues, Methods and Prospects», en *Recent Advances in Memetic Algorithms*, pp. 313-352.

KOCHHAR, J.S. y S.S. HERAGU

1998 «MULTIHOPE: a tool for multiple floor layout problems». *International Journal of production research* 36 (12): 3421-3435.

KOOPMANS, T.C. y M. BECKMAN

1957 «Assignment problems and the location of economic activities». *Economics* 25: 52-76.

KOUVELIS, P., W. CHIANG y J. FITZSIMMONS

1992 «Simulated annealing for machine layout problems in the presence of zone constraints». *European Journal of Operational Research* 57: 203-223.

KUKKONEN, S. y J. LAMPINEN

2004 «An Extension of Generalized Differential Evolution for Multi-objective Optimization with Constraints». *Lecture Notes in Computer Science* 3242: 752-761.

KUSIAK, A. y S.S. HERAGU

1987 «The facility layout problem». *International Journal of production research* 29: 229-251.

LAMPINEN, J.

2001 «DE's selection rule for multiobjective optimization». Lappeenranta University of Technology, Department of Information Technology.

LANDA-BECERRA, R. y C.A. COELLO COELLO

2006 «Solving Hard Multiobjective Optimization Problems Using ϵ -Constraint with Cultured Differential Evolution», en *Parallel Problem Solving from Nature - PPSN IX, 9th International Conference*, Hans-Georg Beyer, Edmund Burke, Juan J. Merelo-Guervos, L. DarrellWhitley, and Xin Yao Thomas Philip Runarsson, ed., pp. 543-552. Reykjavik, Iceland: Springer. Lecture Notes in Computer Science Vol. 4193.

LAWLER, E.L.

1963 «The quadratic assignment problem». *Management Science* 9 (4): 586-599.

LEE, K.-Y., M.-I. ROH y H.-S. JEONG

2005 «An improved genetic algorithm for multifloor facility layout problems having inner structure walls and pasajes». *Computers and Operations Research* 32: 879-899.

LEE, R.C. y J.M. MOORE

1967 «CORELAP - COMputerized RELationship LAYout Planning». *The Journal of Industrial Engineering* 18 (3): 195-200.

LI, H. y D. LANDA-SILVA

2008 «Evolutionary Multi-Objective Simulated Annealing with adaptative and competitive search direction», en *IEEE Congress on Evolutionary Computation (CEC2008)*, pp. 3310-3317. IEEE.

LI, Y. y L. JIAO

2007 «Quantum-inspired immune clonal multiobjective optimization algorithm». *11th Pacific Asia conference on advances in knowledge discovery and data mining* 672-679.

LIGGETT, R.S. y W.J. MITCHELL

1981 «Optimal Space planning in practice». *Computer Aided Design* 13: 277-288.

LIN, J.-L. y C.-H. CHANG

2000 «Solving multiple floor facility layout problems by genetic search». *Proceedings of the 5th Annual International Conference on Industrial Engineering. Theory, Applications and Practice*.

LIN, L.C. y G.P. SHARP

1996a «Quantitative and qualitative indices for plant evaluation problem». *European Journal of production research* 116: 100-117.

1996b «The structured criterion set for plant layout evaluation». *Working paper. Georgia Institute of Technology*. Atlanta.

1999 «Application of the integrated framework for the plant layout evaluation problem». *European Journal of Operational Research* 118-138.

LOGENDRAN, R. y T. KRIAUSAKUL

2006 «A methodology for solving the unequal area facility layout problem». *International journal of production research* 44 (7): 1243-1272.

MADAVAN, N.K.

2002 «Multiobjective Optimization Using a Pareto Differential Evolution Approach», en *Congress on Evolutionary Computation (CEC'2002)*, pp. 1145-1150. Piscataway, New Jersey: IEEE Service Center.

MALAKOOTI, B.

1987 «Computer-Aided facility layout selection (CAFLAS) with applications to multiple criteria manufacturing planning problems». *Large Scale Systems: Theory and Applications, Special Issue on complex Systems Issues in manufacturing* 12: 109-123.

1989 «Multiple objective facility layout: a heuristic to generate efficient alternatives». *International journal of production research* 27 (7): 1225-1238.

MALAKOOTI, B. y G.I. D'SOUZA

1987 «Multiple objective programming for the quadratic assignment problem». *International journal of production research* 25 (2): 285-300.

MALAKOOTI, B. y A. RAVINDRAN

1985 «Experiments with an interactive paired comparison simplex method for MOLP problems». *Annals of Operations Research* 5 (3): 575-597.

MALAKOOTI, B. y A. TSURUSHIMA

1989 «An expert system using priorities for solving multiple-criteria facility layout problems». *International journal of production research* 27 (5): 793-808.

MANIEZZO, V. y A. COLORNI

1995 «Algodesk: an experimental comparison of eight evolutionary heuristics applied to the quadratic assignment problem». *European Journal of Operational Research* 81: 188-204.

MATAI, R. y S.P. SINGH

2008 «Multi-objective facility layout problem: A state of the art review paper». *Sixth AIMS International conference on management* 28-31 december 2008.

MATSUZAKI, K., T. IROHARA y K. YOSHIMOTO

1999 «Heuristic algorithm to solve the multi-floor layout problem with the consideration of elevator utilization». *Computers & Industrial Engineering* 36: 487-502.

MELIAN, B., J.A. MORENO PÉREZ y J.M. MORENO VEGA

2003 «Metaheurísticas: una visión global». *Inteligencia artificial. Reibistaiberoamericana de inteligencia artificial* 7 (19): 7-28.

MELLER, R.D.

1997 «The multi-bay manufacturing facility layout problem». *International Journal of Production Research* 35 (5): 1229-1237.

MELLER, R.D. y Y.A. BOZER

1996 «A new simulated annealing algorithm for the facility layout problem». *International Journal of Production Research* 34 (6): 1675-1692.

1997 «Alternative approaches to solve the multi-floor facility layout problem». *Journal of Manufacturing Systems* 16 (3): 192-203.

MELLER, R.D. y K.Y. GAU

1996 «Facility layout objective functions and robust layouts». *International journal of production research* 34 (10): 2727-2742.

MEZURA-MONTES, E., M. REYES-SIERRA y C.A. COELLO COELLO

2008 «Multi-Objective Optimization using Differential Evolution: A Survey of the State-of-the-Art», en *Advances in Differential Evolution*, pp. 173--196. Berlin: Springer.

MLADENOVIC, N. y P. HANSEN

1997 «Variable Neighbourhood Search». *Computers and operations research* 24 (11): 1097-1100.

MONTREUIL, B. y H.D. RATLIFF

1989 «Utilizing cut tress as design skeletons for facility layout». *IIE Transactions* 21 (2): 136-143.

MOON, G. y K.L. MCROBERTS

1989 «Combinatorial Optimization in Facility Layout». *Computers in Engineering* 17: 43-48.

MOORE, J. y R. CHAPMAN

1999 «Application of particle swarm to multiobjective optimization». Auburn University, Department of computer science and software engineering.

MOORE, J.M.

1962 *Plant Layout and Design*. New York: The Macmillan company.

1971 «Computer program evaluates plant layout alternatives». *Industrial Engineering* 21: 19.

MUTHER, Richard

1955 *Practical Plant Layout*. New York: McGraw-Hill.

1968 *Planificación y proyección de la empresa industrial (Método SLP)*. Barcelona: Editores Técnicos Asociados.

1981 *Distribución en planta*. Editorial Hispano Europea S.A.

NADLER, G.

1965 «What systems really are». *Modern Materials Handling* 20 (7): 41-47.

NAM, D. y C.H. PARK

2000 «Multiobjective Simulated Annealing: A Comparative Study to Evolutionary Algorithms». *International Journal of Fuzzy Systems* 2 (2): 87-97.

2002 «Pareto-Based Cost Simulated Annealing for Multiobjective Optimization», edición de Kay Chen Tan, Takeshi Furuhashi, Jong-Hwan Kim and Xin Yao Lipo Wang. *Proceedings of the 4th Asia-Pacific Conference on Simulated Evolution and Learning (SEAL'02)* 2: 522-526. Singapore.

NEBRO, A.J., F. LUNA y E. ALBA

2005 «New Ideas in Applying Scatter Search to Multiobjective Optimization», edición de Carlos A. Coello Coello and Arturo Hernández Aguirre and Eckart Zitzler. *Evolutionary Multi-Criterion Optimization. Third International Conference, EMO 2005 Lecture Notes in Computer Science* Vol. 3410: 443-458. Guanajuato, México.

NORMAN, B.A., R.A. ARAPOGLU y A.E. SMITH

2001 «Integrated facilities design using a contour distance metric». *IIE Transactions* 33: 337-344.

NORMAN, B.A. y A.E. SMITH

2006 «A continuous approach to considering uncertainly in facility design». *Computers and operations research* 33: 1760-1775.

NUGENT, C.E., T.E. VOLLMAN y J. RUMMLER

1968 «An experimental comparison of techniques for the assignment of facilities to location». *Operations Research* 16: 150-173.

OEI, C.K., D.E. GOLDBERG y S.J. CHANG

1991 «Tournament Selection, Niching,». University of Illinois at Urbana-Champaign, Technical Report 91011.

OSMAN, I.H. y J.P. KELLY

1996 *Meta-heuristics: theory and applications*. Kluwer.

OZDEMIR, G., A.E. SMITH y B.A. NORMAN

2003 «Incorporating heterogeneous distance metrics within block layout design». *International Journal of production research* 41 (5): 1045-1056.

PARSOPOULOS, K.E., D.K. TAOULIS, N.G. PAVLIDIS, V.P. PLAGIANAKOS y M.N. VRAHATIS

2004 «Vector Evaluated Differential Evolution for Multiobjective Optimization», en *2004 Congress on Evolutionary Computation (CEC'2004)*, pp. 204-211. Portland, Oregon: IEEE Service Center.

PATSIATZIS, D.I. y L.G. PAPAGEORGIOU

2002 «Optimal multi-floor process plant layout». *Computers and chemical engineering* 26: 575-583.

2003 «Efficient Solution Approaches for the Multifloor Process Plant Layout Problem». *Industrial Engineering Chemical Research* 42: 811-824.

PRICE, K.

1999 «An introduction to differential evolution», en *New Ideas in Optimization*, pp. 79-108. London, UK: McGraw-Hill.

PRICE, K. y R. STORN

1996 «Minimizing the Real Functions of the ICEC'96 contest by Differential Evolution». *International Conference on Evolutionary Computation (ICEC'96)* 842-844.

RAMAN, D., S.V. NAGALINGAM y G.C.I. LIN

2009 «Towards measuring the effectiveness of a facilities layout». *Robotics and Computer-Integrated Manufacturing* 25: 191-203.

RAOOT, A.D. y A. RAKSHIT

1993a «A 'linguistic pattern' approach for multiple criteria facility layout problems». *International journal of production research* 31 (1): 203-222.

1993b «An experimental comparison of systematic placement procedures for facility layout design». *International Journal of Production Research* 31 (7): 1735-1756.

REED, R. Jr.

1961 *Plant layout: Factors, Principles and techniques*. Homewood, Ill: R.D. Irwin.

REYES-SIERRA, M. y C.A. COELLO COELLO

2006 «Multiobjective Particle Swarm Optimizers: A survey of the state of Art». *Journal of computational Intelligence Research* 2 (3): 287-308.

ROBIC, T. y B. FILIPIC

2005 «DEMO: Differential Evolution for Multiobjective Optimization», edición de Arturo Hernandez Aguirre, and Carlos A. Coello Coello. *Evolutionary Multi-Criterion Optimization. Third International Conference, EMOO 2005* 520-533. Guanajuato, Mexico.

ROSENBLATT, M.J.

1979 «The facilities layout problem: a multi-goal approach». *International journal of production research* 17 (4): 323-332.

1983 «A note on "A multigoal heuristic for facilities design problems:MUGHAL"». *International Journal of production research* 21 (3): 437-439.

ROSENBLATT, M.J. y H.L. LEE

1987 «A robustness approach to facilities layout». *International Journal of Production Research* 25 (4): 479-486.

ROSENBLATT, M.J. y Z. SINUANY-STERM

1986 «A discrete efficient frontier approach to the plant layout problem». *Material Flow* 3: 227-281.

SAATY, T.L.

1986 «Axiomatic Foundation of the Analytic Hierarchy Process». *Management Science* 32: 841-855.

SAHIN, R. y O. TÜRKBEY

2009 «A simulated annealing algorithm to find approximate Pareto Optimal solutions for the multi-objective facility layout problem». *International Journal of Advanced Manufacturing Technology* 41: 1003-1018.

SANGWAN, K.S. y R. KODALI

2006 «Multicriteria heuristic model for design of facilities layout using fuzzy logic and AHP». *International journal of industrial engineering theory applications and practice* 13 (4): 364-373.

SANTAMARINA, C.

1995 *Métodos de optimización en la generación de distribuciones de plantas industriales mediante la aplicación de algoritmos genéticos y técnicas basadas en arboles de cortes*. Tesis Doctoral. Universidad Politécnica de Valencia.

SANTANA-QUINTERO, L.V. y C.A. COELLO COELLO

2005 «An Algorithm Based on Differential Evolution for Multi-Objective Problems». *International Journal of Computational Intelligence Research* 1 (2): 151-169.

SARIN, S.C., P. LOHARJUN, C.J. MALMBORG y B. KRISHNAKUMAR

1992 «A multiattribute decision-theoretic approach for the layout design problem». *European Journal of Operational Research* 57 (2): 231-242.

SAYIN, B.

1981 *Facilities Layout with multiple objectives*. PhD Thesis. Department of Industrial Engineering, University, North Carolina State.

SCHAFFER, J.D.

1984 *Multiple objective optimization with vector evaluated genetic algorithms*. PhD thesis, University of Vanderbilt.

SCRIABIN, M. y R.C. VERGIN

1985 «A cluster-analytic approach to facility layout». *Management Science* 33-49.

SEEHOF, J.M. y W.O. EVANS

1967 «Automated Layout Design Program». *The Journal of Industrial Engineering* 18 (12): 690-695.

SEPPÄNEN, J. y J.M. MOORE

1970 «Facilities planning with graph theory». *Management Science* 17 (4): 242-253.

SERAFINI, P.

1985 «Mathematics of Multiobjective Optimization». *CSIM Courses and Lectures* 289. Berlin.

1992 «Simulated annealing for multiple objective optimization problems». *Proceedings of the Tenth International Conference on Multiple Criteria Decision Making* 87-96. Taipei.

1994 «Simulated annealing for multiple objective optimization problems», en *Multiple Criteria Decision Making. Expand and Enrich the Domains of Thinking and Application*, pp. 283-292. Berlin: Springer-Verlag.

SHA, D.Y. y C.-W. CHEN

2001 «A new approach to the multiple objective facility layout problem». *Integrated Manufacturing Systems* 12 (1): 59-66.

SHANG, J.S.

1993 «Multicriteria facility layout problem:An integrated approach». *European Journal of Operational Research* 66 (3): 291-304.

SHORE, R.H. y J.A. TOMPKINS

1980 «Flexible facilities design». *AIIE Transactions* June.

SIMMONS, D.M.

1969 «One dimensional space allocation: an ordering algorithm». *Operations Research* 17: 812-826.

SINGH, S.P. y V.K. SINGH

2009 «An improved heuristic approach for multi-objective facility layout problem». *International Journal of Production Research*.

SMITH, K.I.

2006 *A Study of Simulated Annealing Techniques for Multi-Objective Optimisation*. Phd Thesis. University of Exeter, UK.

SMITH, K.I., J.E. FIELDSEND, C. MURPHY y R. MISRA

2008 «Dominance-Based Multiobjective Simulated Annealing». *IEEE Transactions on Evolutionary Computation* 12 (3): 323-341.

SRINIVAS, N. y K. DEB

1994 «Multiobjective Optimization Using Nondominated Sorting in Genetic Algorithms». *Evolutionary Computation* 2 (3): 221-248.

STOCKMEYER, L.

1983 «Optimal orientations of cells in slicing floorplan designs». *Information and control* 57: 91-101.

SUMAN, B.

2002 «Multiobjective simulated annealing--A metaheuristic technique for multiobjective optimization of a constrained problem». *Foundations of Computing and Decision Sciences* 27 (3): 171-191.

2003 «Simulated Annealing-Based Multiobjective Algorithms and Their Application for System Reliability». *Engineering Optimization* 35 (4): 391-416.

2004 «Study of simulated annealing based algorithms for multiobjective optimization of a constrained problem». *Computers & Chemical Engineering* 28: 1849-1871.

2005 «Study of self-stopping PDMOSA and performance measure in multiobjective optimization». *Computers & Chemical Engineering* 29 (5): 1131-1147.

SUMAN, B. y P. KUMAR

2006 «A survey of simulated annealing as a tool for single and multiobjective optimization». *Journal of the Operational Research Society* 57 (10): 1143-1160.

SUPPAPITNARM, A., K.A. SEFFEN, G.T. PARKS y P.J. CLARKSON

2000 «A simulated annealing algorithm for multiobjective optimization». *Engineering Optimization* 33 (1): 59-85.

SURESH, G. y S. SAHU

1993 «Multiobjective facility layout using simulated annealing». *International journal of production economics* 32: 239-254.

TAM, K.Y. y S.G. LI

1991 «A hierarchical approach to the facility layout problem». *International Journal of production research* 27 (4): 165-184.

1992 «A simulated annealing algorithm for allocating space to manufacturing cells». *International Journal of production research* 30 (1): 63-87.

TAMAKI, H., H. KITA y S. KOBAYASHI

1996 «Multi-Objective optimization by genetic algorithms: A review», edición de Toshio Fukuda y Takeshi Furuhashi. *Proceedings of the 1996 International conference on evolutionary computation (ICEC'96)* 517-522. Nagoya, Japan.

TATE, D.M. y A.E. SMITH

1995 «Unequal-area facility layout by genetic search». *IIE Transactions* 27: 465-472.

TEKINALP, O. y G. KARSLI

2007 «A new multiobjective simulated annealing algorithm». *Journal of Global Optimization* 39: 49-77.

TOMPKINS, J.A.

1978 «How to gather the data you need». *Modern Materials Handling* June: 50-56.

TOMPKINS, J.A. y R. REED

1976 «An applied model for the facilities design problem». *International Journal of production research* 14 (5): 583-595.

TOMPKINS, J.A. y J.A. WHITE

1984 *Facilities Planning*. John Wiley & Sons.

TOMPKINS, J.A., J.A. WHITE, Y.A. BOZER, E.H. FRAZELLE, J.M.A. TANCHOCO y J. TERVINO

1996 *Facilities Planning*. New York: John Wiley and sons.

TOMPKINS, J.A., J.A., Bozer, Y.A. WHITE y J.M.A. TANCHOCO

2003 *Facilities Planning*. John Wiley & Son.

TONG, X.

1991 *SECOT: a sequential construction technique for facility design*. PhD Thesis. University of Pittsburg.

TOSCANO PULIDO, G. y C.A. COELLO COELLO

2003 «The Micro Genetic Algorithm 2: Towards Online Adaptation in Evolutionary Multiobjective Optimization», en *Evolutionary Multi-Criterion Optimization. Second International Conference, EMO 2003*, Peter J. Fleming, Eckart Zitzler, Kalyanmoy Deb and Lothar Thiele Carlos M. Fonseca, ed., vol. Lecture Notes in Computer Science 2632, pp. 252-266. Faro, Portugal: Springer.

TUZKAYA, U.R., T. ERTAY y D. RUAN

2005 «Simulated annealing approach for the multi-objective facility layout problem». *Studies in Computational Intelligence* 5: 401-418.

ULUNGU, E.L., J. TEGHEM y P. FORTEMPS

1995 «Heuristics for multi-objective combinatorial optimization by simulated annealing», edición de G. Chen, Q. Wei, and S. Wang J. Gu. *Multiple Criteria Decision Making: Theory and Applications. Proceedings of the 6th National Conference on Multiple Criteria Decision Making* 228-238. Windsor, UK.

ULUNGU, L.E., J. TEGHEM, P. FORTEMPS y D. TUYTTENS

1999 «MOSA Method: a tool for solving multiobjective combinatorial optimization problems». *Journal of Multicriteria Decision Anal* 8: 221-236.

UPTON, D.M.

1994 «The management of manufacturing flexibility». *California Management Review* winter: 72-89.

URBAN, T.L.

1987 «A multiple criteria model for the facilities layout problem». *International journal of production research* 25 (12): 1805-1812.

1989 «Combining qualitative and quantitative analyses in facility layout». *Production and inventory management journal* 3: 73-77.

VAN CAMP, D.J., M.W. CARTER y A. VANELLI

1991 «A nonlinear optimization approach for solving facility layout problems». *European Journal of Operations Research* 57: 174-189.

VAN LAARHOVEN, P.J.M. y E.H.L. AARTS

1987 *Simulated Annealing: Theory and applications*. Kluwer Academic Publishers.

VAN VELDHIJZEN, D.A. y G. LAMONT

2000 «Multiobjective Optimization with Messy Genetic Algorithms», en *Proceedings of the 2000 ACM Symposium on Applied Computing*, pp. 470-476. Villa Olmo, Como, Italy: ACM.

WAGHODEKAR, P.H. y S. SAHU

1986a «A critique of some current plant layout techniques». *International journal of operations & production management* 6 (1): 54-61.

1986b «Facilities layout with multiple objectives: MFLAP». *Engineering cost and production economics* 10: 105-112.

WANG, M.J., M.H. HU y M.Y. KU

2005 «A solution to the unequal area facilities layout problem by genetic algorithm». *Computers in Industry* 56: 207-220.

WEBSTER, D.B. y M.B. TYBERGHEIN

1979 «Measuring flexibility». *V International conference on production research*. Amsterdam.

WELGAMA, P.S. y P.R. GIBSON

1993 «A construction algorithm for the machine layout problem with fixed pick up and drop off points». *International Journal of production research* 31: 2575-2590.

WONG, D.F. y C.L. LIU

1986 «A new algorithm for floorplan design». *23rd Design Automation Conference* 7: 101-107.

XUE, F., A.C. SANDERSON y R.J. GRAVES

2003 «Pareto-based Multi-Objective Differential Evolution», en *Proceedings of the 2003 Congress on Evolutionary Computation (CEC'2003)*, vol. 2, pp. 862-869. Canberra, Australia: IEEE Press.

YANG, T. y C.C. HUNG

2007 «Multiple-attribute decision making methods for plant layout design problem». *Robotics and Computer-Integrated Manufacturing* 23: 126-137.

YANG, T. y C. KUO

2003 «A hierarchical AHP/DEA methodology for the facilities layout design problem». *European Journal of Operational Research* 147: 128-136.

YANG, T. y B.A. PETERS

1998 «Flexible machine layout design for dynamic and uncertain production environments». *European Journal of Operational Research* 108 (1): 49-64.

YE, M. y G. ZHOU

2007 «A local genetic approach to multi-objective, facility layout problems with fixed aisles». *International journal of production research* 45 (22): 5243-5264.

ZITZLER, E. y L. THIELE

1998 «An Evolutionary Algorithm for Multiobjective Optimization: The Strength Pareto Approach». Swiss Federal Institute of Technology (ETH), Computer Engineering and Communication Networks Lab (TIK). Zurich, Switzerland.

ZITZLER, E., M. LAUMANN y L. THIELE

2001 *SPEA2: Improving the Strength Pareto Evolutionary Algorithm*. Swiss Federal Institute of Technology (ETH), Computer Engineering and Networks Laboratory (TIK). Zurich: Technical Report 103.

ZYDALLIS, J., D.A VAN VELDHUIZEN y G. LAMONT

2001 «A Statistical Comparison of Multiobjective Evolutionary Algorithms Including the MOMGA-II», en *First International Conference on Evolutionary Multi-Criterion Optimization*, Kalyanmoy Deb, Lothar Thiele, Carlos A. Coello Coello and David Corne Eckart Zitzler, ed., pp. 226-240. Springer-Verlag.