



UNIVERSITAT POLITÈCNICA DE VALÈNCIA
DEPARTAMENTO DE INGENIERÍA MECÁNICA Y DE MATERIALES

TESIS DOCTORAL

**Estudio de redes neuronales y modelos de cuadripolos
para la solución del problema inverso en ensayos no destructivos
por medio de corrientes inducidas.
Aplicación para el control de espesores en superficies metálicas
con protección multicapa**

Autor:

Adrián Corbí Cabrera

Dirigida por:

Dr. José Enrique Crespo Amorós
Dr. Manuel Pascual Guillamón
Dr. Samuel Sánchez Caballero

Enero 2016

Dedicat a Dori, a Carolina y a Elisa

Agraïments

A don Carlos Ferrer Gimenez, sense que el seu empenyi el treball no s'hauria obert aquesta aventura.

A Jose Enrique Crespo, a Manuel Pascual i a Samuel Sánchez els directors d'aquest treball per la seva inestimable ajuda.

Als companys del DIMM i especialment a Fidel i a Matías pel seu suport i consells

A Roberto i a Honorio per l'ajuda en el muntatge

«Estudio de redes neuronales y modelos de cuadripolos para la solución del problema inverso en ensayos no destructivos, por medio de corrientes inducidas. Aplicación para el control de espesores en superficies metálicas con protección multicapa»

Resumen

En la actualidad el uso de métodos de prueba empleando ensayos de corrientes inducidas se ha generalizado en la industria, no sólo en el campo de los ensayos no destructivos, para estudiar el comportamiento de las grietas en elementos sujetos a fatiga así como para detectar fallas en la estructura interna metálica, sino también como instrumentos de medida para obtener información de la caracterización de los materiales, composición de las capas superficiales, magnitud de la oxidación superficial, espesor de las capas superficiales tratadas para su endurecimiento. Sin embargo, la aplicación de corrientes inducidas para conocer el dimensionado de capas superficiales puede resolverse mediante el problema directo pero no así el inverso, obtener a partir de las mediciones de parámetros electromagnéticos, las dimensiones de las capas estratificadas en la superficie del metal. Este caso singular es el que trata de resolver esta tesis de manera que empleando un modelado que sustituye las distintas capas físicas del material, por elementos cuadripolares o cuadripolos, de cuyo comportamiento se puede establecer el paralelismo con que aparecen las corrientes inducidas en la superficie del metal en condiciones reales. Para esto, se han tomado varios juegos de placas con distintos espesores conocidos y se han medido sus impedancias características mediante sensores adecuados. Los resultados obtenidos sirven para entrenar una red neuronal artificial, y por tanto deben de permitir su empleo para resolver el problema inverso, es decir, a partir de las lecturas de la medición como entrada de la red neuronal obtener las dimensiones buscadas a la salida.

Los trabajos se inician con un estudio detallado de las soluciones a las ecuaciones de campos electromagnéticos armónicos y para el modelo que se propone. Se usa el método vectorial del potencial vector magnético con las condiciones de contraste de Coulomb. Se estudian la propagación de señales en las proximidades de la superficie y en la región frontera. Se establece la formulación básica de las corrientes inducidas y se estudian con detalle dos problemas concretos y sus modelos, el de una placa de espesor finito y el de un cilindro.

Con todo ello se propone un método de resolución de las ecuaciones del problema mediante el empleo de series numéricas en la sustitución de las integrales con límite superior infinito. Se obtienen resultados para el cálculo de los parámetros resultantes en función de la frecuencia de ensayo y para un modelo establecido. Se propone un modelo de simulación ANSYS con dos soluciones, en la primera se emplea un modelo plano PLANE53 y en la segunda un modelo tridimensional SOLID236. A partir de este último se estudia la sensibilidad del ensayo de corrientes inducidas por comparación de resultados al modificar las condiciones del medio, permeabilidad y conductividad. También se propone un modelo de propagación de señal similar al de una línea de transmisión en telecomunicaciones, para ello se establecen modelos de cuadripolos y se conectan en cadena, los resultados teóricos se obtienen por las distintas frecuencias y sirven para mostrar un método de medida u control de los distintos espesores.

«Estudi de xarxes neuronals i models de quadripols per a la solució del problema invers en assajos no destructius, per mitjà de corrents induïts. Aplicació per al control de gruixos en superfícies metàl·liques amb protecció multicapa»

Resum

En l'actualitat l'ús de mètodes de prova emprant assaigs de corrents induïts s'ha generalitzat en la indústria, no només en el camp dels assajos no destructius, per estudiar el comportament de les esquerdes en elements subjectes a fatiga així com per detectar falles en l'estructura interna metàl·lica, sinó també com a instruments de mesura per obtenir informació de la caracterització dels materials, composició de les capes superficials, magnitud de l'oxidació superficial, espessor de les capes superficials tractades per al seu enduriment. No obstant això, l'aplicació de corrents induïts per conèixer el dimensionament de capes superficials pot resoldre mitjançant el problema directe però no així l'invers, obtenir a partir dels mesuraments de paràmetres electromagnètics, les dimensions de les capes estratificades en la superfície del metall. Aquest cas singular és el que tracta de resoldre aquesta tesi de manera que emprant un modelatge que substitueix les diferents capes físiques del material, per elements quadripolars o quadripols, del comportament es pot establir el paral·lelisme amb què apareixen els corrents induïdes en la superfície del metall en condicions reals. Per això, s'han pres diversos jocs de plaques amb diferents gruixos coneguts i s'han mesurat les seves impedàncies característiques mitjançant sensors adequats. Els resultats obtinguts serveixen per entrenar una xarxa neuronal artificial, i per tant han de permetre la seva ocupació per resoldre el problema invers, és a dir, a partir de les lectures del mesurament com a entrada de la xarxa neuronal obtenir les dimensions buscades a la sortida.

Els treballs s'inicien amb un estudi detallat de les solucions a les equacions de camps electromagnètics harmònics i per al model que es proposa. Es fa servir el mètode vectorial del potencial vector magnètic amb les condicions de contrast de Coulomb. S'estudien la propagació de senyals en les proximitats de la superfície hi ha la regió frontera. S'estableix la formulació bàsica dels corrents induïts i s'estudien amb detall dos problemes concrets i els seus models, el d'una placa de gruix finit i el d'un cilindre.

Amb tot això es proposa un mètode de resolució de les equacions del problema mitjançant l'ús de sèries numèriques en la substitució de les integrals amb límit superior infinit. S'obtenen resultats per al càlcul dels paràmetres resultants en funció de la freqüència d'assaig i per a un model establert. Se proposa un model de simulació ANSYS amb dues solucions, en la primera es fa servir un model pla PLANE53 i en la segona un model tridimensional SOLID236. A partir d'aquest últim s'estudia la sensibilitat de l'assaig de corrents induïts per comparació de resultats en modificar les condicions del medi, permeabilitat i conductivitat. També es proposa un model de propagació de senyal similar al d'una línia de transmissió en telecomunicacions, per això s'estableixen models de quadripols i es connecten en cadena, els resultats teòrics s'obtenen bat les diferents freqüències i serveixen per mostrar un mètode de mesura o control dels diferents gruixos.

«Study of neural networks and quadrupole models for the solution of the inverse problem in non-destructive testing by eddy currents. Application control of thickness on metal surfaces with multilayer protection»

Abstract

Currently the use of test methods using eddy current testing has become widespread in the industry, not only in the field of non-destructive testing, to study the behavior of cracks in components subject to fatigue and to detect failures metal internal structure, but also as measuring instruments to obtain information from the characterization of materials, composition of the surface layers, surface oxidation extent of the thickness of the surface layers treated for hardening. However, the application of currents induced to meet sizing surface layers can be solved by direct problem but not the reverse, obtained from measurements of electromagnetic parameters, the dimensions of the laminated layers on the metal surface. This unique case is trying to solve this thesis so that replaces modeling using different physical layers of the material, quadrupole or quadrupole elements, whose behavior can set the parallel appearing in induced surface currents metal under real conditions. For this, they have taken several sets of plates with different known thicknesses are measured and their characteristic impedances by suitable sensors. The results obtained are used to train an artificial neural network, and therefore should allow its use to solve the inverse problem, i.e., from readings measured as input to the neural network to obtain the dimensions wanted to check out.

The work begins with a detailed study of the solutions to equations and harmonic electromagnetic fields for the model proposed. The method of the magnetic vector potential vector with Coulomb contrast conditions used. Signal propagation near the surface and in the border region are studied. The basic formulation of the induced currents is established and studied in detail two specific problems and their models, the finite thickness plate and a cylinder.

However, this method of solving the equations of the problem is proposed by using numerical series in replacing the integrals with infinite upper limit. Results to calculate the resulting model parameters based on the obtained test frequency and for a model settled down. We proposes a simulation model ANSYS two solutions, the first a plane model is used PLANE53 and second dimensional model SOLID236. From the latter assay sensitivity of currents induced by benchmarking the environmental conditions change, permeability and conductivity are studied. A model similar to the propagation of a transmission line in telecommunications models for that quadrupoles are set and are daisy-chained signal is also proposed theoretical results are obtained even different frequencies and are used to show a method of measuring or control of different thicknesses.

Nomenclátor y unidades SI

A	Potencial Vector	Wb/m
B	Inducción Magnética	T
c	Dimensionado bobina	m
D	Inducción Eléctrica	C/m ²
E	Intensidad de Campo Eléctrico	V/m
f	Frecuencia	Hz
H	Intensidad de Campo Magnético	A/m
J	Densidad de Corriente Eléctrica	A/m ²
j	Unidad imaginaria	
k	Número de Ondas	1/m
l1	Dimensionado bobina	m
l2	Dimensionado bobina	m
M	Imanación	A/m
n	Vector unitario normal	
n	Número de espiras	
P	Potencia	W
r1	Dimensionado bobina	m
r2	Dimensionado bobina	m
Rs	Resistencia Superficial	Ω
s	Conductividad Eléctrica	S/m
t	Tiempo	s
Z	Impedancia Eléctrica	Ω
α	Componente real de k	
α	Constante ecuación diferencial	
β	Componente imaginaria de k	
δ	Profundidad de Penetración	m
ε	Permitividad Eléctrica	F/m
μ	Permeabilidad Magnética	H/m
ρ	Densidad de Carga Eléctrica	C
χ	Susceptancia Magnética	
ω	Velocidad angular	rad/s

Salviati.- Al investigar las razones desconocidas de las conclusiones hay que tener la suerte de dirigir, desde el principio, el razonamiento hacia el camino de la verdad.

Diálogo sobre los dos máximos sistemas del mundo Ptolemaico y Copernicano.

Galileo Galilei Pisa 1564-Arceti 1642 [1]

...“una fuerza divina es la que te mueve, parecida a la que hay en la piedra que Eurípides llamó magnética, y la mayoría heraclea. Por cierto, que esta piedra no sólo atrae a los anillos de hierro, sino que mete en ellos una fuerza tal, que pueden hacer lo mismo que la piedra, o sea, atraer otros anillos, de modo que a veces puede formarse una larga cadena de anillos de hierro que penden unos de otros y cuya fuerza les viene de la piedra”...

Platón Ión 499 a.d.n.e. [2],[3]

<<Empédocles dice que el hierro se mueve hacia el imán debido a los efluvios que emanan de ambos, así como merced a los poros del imán que son simétricos respecto al efluvio del hierro. Los efluvios del imán expulsan el aire que cierra los poros. Cuando éste resulta expulsado, el hierro sigue inmediatamente la corriente de sus propios efluvios, pues cuando dichos efluvios se mueven hacia los poros del imán debido a que son simétricos y encajan con ellos, el hierro junto con sus efluvios se mueve hacia el imán>>

Alejandro de Afrodisia 200 a.d.n.e. [4]

Justificación

En el amplio sector industrial y dentro del campo del Control de Calidad se emplean diversos métodos de ensayos y pruebas para la información básica, sobre todo para la prevención de los posibles fallos de construcción o de uso que comporten el deterioro y/o la rotura de los componentes. Desde el control visual de fabricación a mantenimiento hasta sofisticados ensayos de laboratorio.

Se hacen necesarios para el mantenimiento de la calidad en servicio de los diversos componentes. Una parcela muy amplia de estos ensayos son los denominados no destructivos: es decir aquellos que su empleo no constituye un deterioro o destrucción de la pieza así se emplean líquidos penetrantes, de contraste, partículas magnéticas etc. y el más extendido que es el del empleo de corrientes de Foucault por su facilidad de empleo y su eficacia se usa para la detección de grietas superficiales o sub superficiales, medidas de espesores de capas de recubrimiento, de pintura no conductora, identificación de materiales, etc. su uso está condicionado a que el material que soporte el ensayo sea conductor en general metálico. En la aplicación específica de medición de espesores de placas o tubos metálicos es de gran uso y eficacia para lo que se han desarrollado equipos específicos para ese uso. Sin embargo en el análisis más detallado del ensayo por corrientes de Foucault se observa que se pueden obtener más parámetros del medio que se observa tales como la conductividad eléctrica la permeabilidad magnética es decir características que nos suministran información sobre la caracterización del material. Profundizando en esta aplicación observamos que es posible además confeccionar un método que resulte eficaz para el control de fabricación en el caso de piezas (planchas o tubos) que contengan en su superficie distintas capas de protección que para conocer su dimensionado (espesores) en el proceso de fabricación o en el control de mantenimiento ante la aparición del desgaste (modificación del espesor) o la corrosión/oxidación que modificaría su composición química. No habiendo encontrado en el mercado equipos que resuelvan esta cuestión proponemos mediante el uso de un equipo convencional para realizar mediciones de impedancia eléctrica, que una vez procesadas nos den nos proporcionen la información precisa. Para este proceso proponemos un modelo electromagnético de red cuadripolar al que después de aplicar los parámetros adecuados simule el comportamiento de las distintas capas de protección ante el ensayo de corrientes de Foucault y nos sirva para obtener los resultados adecuados.

1	Estado del Arte.....	25
1.1	Revisión bibliográfica	27
1.1.1	Fuentes de información y funciones de búsqueda	27
1.2	Antecedentes históricos.....	31
1.3	Fundamentos de las corrientes inducidas.....	32
1.3.1	La propagación de la onda electromagnética	32
1.3.2	Campos en las proximidades de superficies	34
1.3.3	Resistencia superficial de una lámina metálica de gran espesor.-	36
1.3.4	Analogía para una línea de longitud infinita.-.....	37
1.4	Las corrientes inducidas.....	39
1.4.1	Solución analítica para los problemas de bobinas sonda detectoras de corrientes inducidas.....	39
1.4.2	Estudio de una placa de espesor finito	42
1.4.3	Estudio de un cilindro.....	45
1.4.4	Circuito equivalente.....	50
1.4.5	Modelado ANSYS.....	52
1.4.6	Resultados.....	55
1.4.7	Conclusiones	57
1.5	Magnetismo y cuestiones relacionadas	58
1.5.1	Causas de la histéresis	58
1.5.2	Comportamiento con campos débiles: Ley de Raleigh	59
1.5.3	Comportamiento en campo intenso: Ley en la proximidad de la saturación.-	60
1.5.4	Curva de magnetización. Modelo Frönlich- Kennelly.....	61
1.5.5	Campos magnéticos de medición.....	62
2	Objetivos y planificación	63
2.1	Objetivos.....	65
2.1.1	Antecedentes.-	65
2.1.2	Planificación.....	65
2.2	Procedimientos.....	66
2.3	Equipos de medida.....	66
2.3.1	Equipo Defectoscop F140d.....	66
2.3.2	Equipo HP 4294 A.....	68

2.3.3	Dispositivos.-.....	70
2.3.4	Conexión USB/GPIB.....	72
3	Métodos numéricos.....	73
3.1	Introducción.....	75
3.2	Desarrollo en series.....	75
3.3	Aspectos del cálculo.....	79
4	Simulación ANSYS.....	81
4.1	Introducción.....	83
4.2	Modelo plano.....	83
4.3	Modelo tridimensional.....	86
4.3.1	Solid236.....	86
4.3.2	Resultados numéricos.....	91
5	Modelo de cuadripolos.....	93
5.1	Introducción.....	95
5.2	Resultados del modelo teórico.....	105
5.2.1	Representación gráfica.....	105
6	Medidas.....	107
6.1	Medidas ópticas (probetas X).....	109
6.2	Plan establecido.-.....	109
6.3	Equipos.....	109
6.3.1	Resultados de la medidas ópticas.....	110
6.3.2	Resultados de las medidas electromagnéticas.....	117
6.3.3	Conclusiones.....	119
7	Método inverso.....	121
7.1	Introducción.....	123
7.2	Método de resolución del Problema Inverso.....	123
8	Redes neuronales artificiales.....	127
8.1	Antecedentes históricos.....	129
8.1.1	Antecedentes.....	130
8.1.2	Introducción.....	130
8.2	Redes Neuronales Artificiales.....	131

8.3	Introducción a la tecnología RNA	131
8.3.1	¿Qué es una red neuronal artificial?	132
8.3.2	Las analogías entre los sistemas nervioso y las RNA	132
8.3.3	Evolución de las técnicas RNA.....	134
8.4	Bases para las RNAs	135
8.4.1	Descripción Marco general	135
8.4.2	Neuronas y capas	136
8.4.3	Estado de activación	137
8.4.4	Salida de las neuronas.....	137
8.4.5	Patrón de conectividad.....	138
8.4.6	Regla de propagación.....	139
8.4.7	Regla de activación.....	139
8.4.8	Aprendizaje.....	141
8.5	Representación del entorno	150
8.5.1	Capacidades de mapeo de funciones de RNAs	150
	Correlación de funciones.....	150
8.5.2	Redes feedforward estándar	151
8.5.3	Redes función de base radial (RBF)	152
8.5.4	RNAs temporales.....	154
8.5.5	Red neuronal con tiempo de retardo (TDNN).....	155
8.5.6	Red neuronal feedforward con retraso de tiempo distribuido (DTLFNN)	156
8.5.7	Red recurrente simple (SRN).....	157
8.5.8	Predicciones adelantadas multi-paso	158
8.5.9	Método recursivo de varios pasos (también denominado: predicción reiterada); 159	
8.6	Encadenamiento de RNAs;	159
8.6.1	Método de multi pasos directo.....	159
8.7	Aspectos de rendimiento de las RNA	160
8.7.1	Ventajas y desventajas de las RNA	160
8.7.2	Sobre entrenamiento.....	163
8.7.3	Infra ajuste	167
9	Modelos de red y optimización	169

9.1 Enfoque del Algoritmo Genético Multiobjetivo	171
9.1.1 Prefacio.....	171
9.2 Algoritmos genéticos multiobjetivo.....	172
9.2.1 Introducción.....	172
9.2.2 Estructura general de un Algoritmo Genético	173
9.2.3 Explotación y Exploración.....	174
9.2.4 Búsqueda basada en la población.....	174
9.2.5 Ventajas Principales.....	175
9.2.6 Aplicación de los Algoritmos Genéticos	176
9.2.7 Vocabulario del AG	176
9.3 Codificación	177
9.3.1 Clasificación de las codificaciones	177
9.3.2 Inviabilidad y la ilegalidad.....	178
9.3.3 Propiedades de las codificaciones	179
9.3.4 Inicialización	180
9.3.5 Evaluación de la aptitud.....	180
9.4 Los operadores genéticos	180
9.4.1 Cruce.....	181
9.4.2 Mutación	182
9.4.3 Selección	183
9.5 Restricciones de manipulación.....	184
9.5.1 Estrategia de Rechazo	185
9.5.2 Estrategia de Reparación.....	185
9.5.3 Estrategia de los operadores de modificación genética.....	185
9.5.4 Estrategia penalizante	186
9.6 Algoritmos genéticos híbridos.....	186
9.6.1 Búsqueda genética local.....	186
9.6.2 Parámetro Adaptación.....	190
9.6.3 Clasificación de parámetro Adaptación.....	191
9.7 Algoritmos Genéticos con multi-objetivo.....	198
9.8 Conceptos básicos de optimizaciones multiobjetivo	198
9.8.1 Soluciones no dominadas.....	199

9.8.2	Características y Aplicación de AG multiobjetivo	201
9.8.3	Mecanismo de Asignación de aptitud.....	203
9.8.4	Enfoque de la Evaluación por Vector: Generación 1.....	203
9.8.5	Clasificación de Pareto + Diversidad: Generación 2	206
9.8.6	Suma ponderada + Protección Elitista: Generación 3.....	207
9.9	Medidas de Rendimiento	214
9.9.1	Conjunto de referencia S*	216
10	Resultados y conclusiones.....	217
10.1	Resultados	219
10.2	Conclusiones.....	223
11	Líneas de trabajo futuras.....	225
11.1	Líneas de trabajo futuras	227
12	Anexos	229
12.1	Anexos ANSYS.....	231
12.1.1	Macros.....	231
12.1.2	Elementos	232
12.2	Anexos Mathcad	236
12.2.1	Ceros de Bessel.....	250
12.3	Anexo Equipamiento	251
12.3.1	Calibrado del equipo Defectoscop.-	251
12.4	Anexo Redes neurales artificiales	252
12.4.1	Ejemplo para Excel de la etapa de aprendizaje	252
12.4.2	Derivación del algoritmo de retropropagación.....	256
12.4.3	El algoritmo de retropropagación.....	259
12.4.4	El algoritmo de backpropagation con gradiente conjugado	261
12.4.5	El algoritmo de Broyden-Goldfarb-Shanno (BFGS).....	265
13	Índices y Referencias	271
13.1	Índice de Gráficas.....	273
13.2	Índice de Figuras	275
13.3	Índice de Tablas	279
13.4	Referencias bibliográficas	281

1 Estado del Arte

1.1 Revisión bibliográfica

Como base de partida para el presente trabajo científico, es importante considerar la documentación previa referida al tema de estudio, como un elemento decisivo a la hora de plantear la viabilidad del mismo y establecer las vías oportunas para alcanzar los objetivos planteados. Por este motivo, se ha realizado una revisión bibliográfica sobre la medición de multicapas empleando corrientes inducidas con la ayuda de redes neuronales para resolver el problema inverso, con el fin de establecer una base sólida de documentación que sirva de apoyo al estudio posterior.

1.1.1 Fuentes de información y funciones de búsqueda

De las diversas bases de datos destacan por su volumen las integradas en el “Science Citation Index”, que se publicó por primera vez en el año 1964 para ofrecer una manera novedosa de buscar información bibliográfica a través de un vínculo temático entre un artículo y las referencias que cita, esta información está comprendida en tres versiones electrónicas de bases de datos multidisciplinares que abarcan todas las ramas de la ciencia, las ciencias sociales, las humanidades y las artes.

En la actualidad todas las series de los “Science Citation Index” están integradas dentro de la denominada “Web of Science” creada en 1997. A su vez esta base de datos está engloba en una plataforma denominada “Web of Knowledge”, que permite la consulta interrelacionada de la “Web of Science”: base de datos que permite la búsqueda de artículos, dispone de un índice de citas, desde 1945; “Journal Citation Report”: que ofrece información de una gran cantidad de publicaciones, como factor de impacto publicaciones por año, citas referidas, etc; la “Derwent Innovation Index”: base de datos de patentes; la “ISI proceedings”: base de datos de actas de congresos; y la “Current Contents Connect”: boletín de sumarios multidisciplinar.

La base de datos bibliográfica “ICYT”, elaborada por el CSIC (Consejo Superior de Investigaciones Científicas) recoge la literatura científica contenida en publicaciones españolas de ciencia y tecnología. Analiza revistas, informes, congresos, libros colectivos, etc. publicados desde 1979 hasta la actualidad. Además, hay una base de datos especial para la consulta de tesis doctorales, denominada “Teseo”, gestionada por el Ministerio de Ciencia Educación y Cultura, donde se recoge y permite recuperar información de las tesis doctorales leídas y consideradas aptas en las Universidades españolas desde 1976.

La plataforma más utilizada para la búsqueda de artículos y trabajos relacionados **c** la medición de multicapas empleando corrientes inducidas con la ayuda de redes neuronales para resolver el problema inverso es la “Web of Knowledge” y concretamente de la base de datos “Web of Science”, debido a la enorme cantidad de citas recogidas en esta base de datos.

En cuanto a las funciones de búsqueda, se realiza por artículos y referencias de trabajos para poder abarcar los máximos resultados; para esto se debe tener en cuenta

qué se pretende conseguir con las búsquedas en las bases de datos anteriormente mencionadas. Una de las principales acciones es la definición de las palabras claves o de la unión de varias palabras claves. Estas palabras claves nos pueden abrir o cerrar el camino a seguir de una buena y exhaustiva búsqueda dentro de las bases de datos.

Las palabras claves utilizadas están dentro de la clasificación de temas generales, como punto de partida del trabajo: Eddy current, neural network, thickness. Se eligen palabras claves sobre los temas principales; estos serán la base principal para el acotamiento de los resultados de las búsquedas. Se han utilizado diferentes palabras claves de búsqueda, y combinaciones con otras palabras para poder cercar más la misma y centralizarla en trabajos algo más concretos, en estas combinaciones de palabras claves se ha utilizado el operador (booleano) “and” para poder acotar la búsqueda con el fin de filtrar los resultados.

Se elabora una búsqueda junto con palabras clave relacionadas con el tema tratado. El resultado obtenido se detalla en la siguiente tabla:

Tabla nº 1.1 Resultados obtenidos sobre la búsqueda con palabras clave.

Palabras clave de búsqueda	Resultados
<i>Eddy current and neural network and thickness</i>	25

Una vez concluida la búsqueda de resultados de trabajos relacionados con las palabras claves más representativas y la combinación de estas, junto con los temas generales enunciados anteriormente, la cantidad de trabajos encontrados son 25. A continuación se detallan los resultados.

- [1] Allred, L. G. In Applications of Artificial Neural Networks in Image Processing V; Nasrabadi, N. M.; Katsaggelos, A. K., Eds., 2000.
- [2] Baseri, H.; Damirchi, H., Prediction of the Ferrite-Core Probe Performance Using a Neural Network Approach, Materials and Manufacturing Processes 2010:25(8):718.
- [3] Bensetti, M.; Le Bihan, Y.; Marchand, C.; Pavo, J., Deposit characterization by eddy current nondestructive evaluation, International Journal of Applied Electromagnetics and Mechanics 2004:19(1-4):537.
- [4] de Alcantara, N., Identification of steel bars immersed in reinforced concrete based on experimental results of eddy current testing and artificial neural network analysis, Nondestructive Testing and Evaluation 2013:28(1):58.
- [5] Habibalahi, A.; Moghari, M. D.; Samadian, K.; Mousavi, S. S.; Safizadeh, M. S., Improving pulse eddy current and ultrasonic testing stress measurement accuracy using neural network data fusion, Iet Science Measurement & Technology 2015:9(4):514.

- [6] Huang, P.; Zhang, G.; Hou, D.; Zhou, Z.; Wu, Z., Modelling and inversion techniques for thickness measurement of multi-layered structures in eddy current testing, *Insight* 2006:48(7):406.
- [7] Janousek, L.; Yusa, N.; Chen, Z.; Miya, K. In *Electromagnetic Nondestructive Evaluation*; Sollier, T.; Premel, D.; Lesselier, D., Eds., 2004.
- [8] Joubert, P.; Lespinet, O.; Le Bihan, Y.; Mikic, A.; Joubert, P. Y.; Le, B. Y.; Snecma; Cnrs Cent Nat Rech Sci; Snecma Moteurs; Snecma Sa.
- [9] Katragadda, G.; Lewis, D.; Wallace, J.; Si, J. T., Swept frequency eddy current material profiling using radial basis function neural networks for inversion, *Materials Evaluation* 2000:58(1):70.
- [10] Koido, J., *COVERING THICKNESS AND DIAMETER MEASUREMENT OF REINFORCING BARS BY EDDY CURRENT TESTING USING NEURAL NETWORK*, 1995.
- [11] Le Bihan, Y., 3-D finite-element analysis of eddy-current evaluation of curved plates, *IEEE Transactions on Magnetics* 2002:38(2):1161.
- [12] Le Bihan, Y.; Joubert, P. Y.; Placko, D., Wall thickness evaluation of single-crystal hollow blades by eddy current sensor, *Ndt & E International* 2001:34(5):363.
- [13] Li, G.; Kang, X.; Huang, P.; Chen, P.; Hou, D.; Zhang, G.; Zhou, Z.; IEEE, *Thickness Measuring of Multilayer Conductor Based on Eddy Current Testing*, 2009.
- [14] May, P.; Zhou, E.; Morton, D., *Intelligent measurement of coating thickness on steel by neural networks*, 2001.
- [15] Preda, G.; Cranganu-Cretu, B.; Hantila, F. I.; Mihalache, O.; Chen, Z. M.; Miya, K., Nonlinear FEM-BEM formulation and model-free inversion procedure for reconstruction of cracks using pulse eddy currents, *IEEE Transactions on Magnetics* 2002:38(2):1241.
- [16] Preda, G.; Hantila, F. I., Nonlinear Integral Formulation and Neural Network-Based Solution for Reconstruction of Deep Defects With Pulse Eddy Currents, *IEEE Transactions on Magnetics* 2014:50(2):
- [17] Ramuhalli, P.; Liu, Z., *Wavelet neural network based data fusion for improved thickness characterization*, 2004.
- [18] Rao, B. P. C.; Arasu, S. T.; Jayakumar, T.; Kalyanasundaram, P.; Raj, B. In *Electromagnetic Nondestructive Evaluation*; Udpa, L.; Bowler, N., Eds., 2005.
- [19] Rao, B. P. C.; Raj, B.; Jayakumar, T.; Kalyanasundaram, P., Using artificial neural networks to quantify discontinuities in eddy current testing, *Materials Evaluation* 2002:60(1):84.
- [20] Rekanos, I. T.; Theodoulidis, T. P.; Panas, S. M.; Tsiboukis, T. D., Impedance inversion in eddy current testing of layered planar structures via neural networks, *Ndt & E International* 1997:30(2):69.
- [21] Shyamsunder, M. T.; Rajagopalan, C.; Raj, B.; Dewangan, S. K.; Rao, B. P. C.; Ray, K. K., Pattern recognition approaches for the detection and characterization of discontinuities by eddy current testing, *Materials Evaluation* 2000:58(1):93.

- [22] Thirunavukkarasu, S.; Rao, B. P. C.; Jayakumar, T.; Kalyanasundaram, P.; Raj, B., Quantitative eddy current testing using radial basis function neural networks, *Materials Evaluation* 2004:62(12):1213.
- [23] Vourc'h, E.; Joubert, P.-Y.; Le Gac, G.; Larzabal, P., Nondestructive evaluation of loose assemblies using multi-frequency eddy currents and artificial neural networks, *Measurement Science & Technology* 2013:24(12):
- [24] Zhang, W.; Qu, S.; Li, L.; Miao, Q.; Song, C.; lee, Application of ANN in the Thickness Measuring of Conductive Materials, 2009.
- [25] Zhang, Z.; Li, X.; lee. In 2014 Sixth International Conference on Measuring Technology and Mechatronics Automation, 2014.

De este número de artículos encontrados y una vez filtrados y revisados, tan sólo tienen una relación directa con los temas tratados 1 artículo.

Huang, P.; Zhang, G.; Hou, D.; Zhou, Z.; Wu, Z., Modelling and inversion techniques for thickness measurement of multi-layered structures in eddy current testing, *Insight* 2006:48(7):406.

El artículo trata de resolver el mismo problema, pero no emplea los mismos medios, ya que modeliza el problema de forma diferente, la formulación funcional es distinta al no emplear métodos numéricos, no emplea el modelo de cuadripolos i finalmente con la red neuronal de retropropagación emplea una red base radial.

1.2 Antecedentes históricos

Ya los griegos intentaron explicar fenómenos derivados de la electrostática o del magnetismo, para ellos indistintos, pero sin base científica experimental.

En 1600 la Reina Elizabeth I ordena al Físico Real William Gilbert (1544-1603) estudiar los imanes para mejorar la exactitud de las brújulas usadas en la navegación, siendo éste trabajo la base principal para la definición de los fundamentos de la electrostática y el magnetismo.

Fue alrededor de 1730 cuando Stephen Gray demostró la existencia de la conducción eléctrica, lo que le facilitó, la separación de materiales en conductores y aislantes.

A mediados del siglo XIX, la Física y en particular la Electricidad y el Magnetismo, desarrollaban sus principios y leyes iniciales que culminarían con la teoría del Campo Electromagnético de Maxwell (1831-1879).

En Europa Jean-Bernad Foucault (1819-1868) publicó hacia 1855 sus trabajos sobre los efectos que se producían en un disco de cobre (conductor) al girar en el seno de un campo magnético creado por un imán: el disco se frenaba, al tiempo que elevaba su temperatura.

En 1820 Hans Christian Oersted (1777-1851) había descubierto la relación que existe entre el magnetismo y la electricidad al observar la desviación que sufre una brújula en las proximidades de un hilo conductor por el que circula una corriente de electricidad.

Enterado André Marie Ampère (1775-1836) de las experiencias de Oersted y con gran intuición, en pocas fechas estableció de forma matemática (Ley de Ampère) la interacción de la fuerza magnética y las corrientes eléctricas.

Michael Faraday (1791-1867) explicó el fenómeno electromagnético, atribuyéndolo a partículas eléctricas en movimiento y no a un fluido continuo.

Se habían establecido las bases científicas del fenómeno de las corrientes inducidas y de sus diversas manifestaciones y aplicaciones, en este trabajo, nos centraremos en el efecto de las corrientes inducidas (turbo millonarias, corrientes de Foucault (Europa) o eddy current (EEUU) que de tales formas suelen ser denominadas.

El inicio del uso industrial del fenómeno de las corrientes inducidas lo emprende Fiedrich Förster hacia los años 30, done desarrolla equipos para la medición de la conductividad y de clasificación para los materiales ferromagnéticos. En 1948 funda la compañía dedicada a este campo, en activo en la actualidad.

1.3 Fundamentos de las corrientes inducidas

1.3.1 La propagación de la onda electromagnética

En un medio homogéneo, isótropo e ideal, consideramos el análisis de la propagación de un campo electromagnético.

Las ecuaciones del medio muestran la influencia del soporte físico sobre los campos electromagnéticos, la ϵ permitividad y la μ permeabilidad proporcionan la respuesta del medio al campo eléctrico y magnético respectivamente. La tercera ecuación muestra la ley de Ohm generalizada en la que el parámetro que la define es la conductividad σ .

Ecuaciones el medio

Ecuación nº 1.1

$$\begin{aligned} \mathbf{D} &= \epsilon \cdot \mathbf{E} \\ \mathbf{B} &= \mu \cdot \mathbf{H} \\ \mathbf{J} &= \sigma \cdot \mathbf{E} \end{aligned}$$

La resolución de las ecuaciones de Maxwell proporcionan los modos de propagación de los campos electromagnéticos así como sus características

Ecuaciones de Maxwell

Ecuación nº 1.2

$$\begin{aligned} \nabla \cdot \mathbf{D} &= \rho_f \\ \nabla \cdot \mathbf{B} &= 0 \\ \nabla \wedge \mathbf{E} + \frac{\partial \mathbf{B}}{\partial t} &= 0 \\ \nabla \wedge \mathbf{H} - \frac{\partial \mathbf{D}}{\partial t} &= \mathbf{J}_f \end{aligned}$$

En las que ρ_f y \mathbf{J}_f son las cargas y distribución de cargas libres respectivamente
Al operar sobre ellas se obtienen las ecuaciones de onda:

Ecuaciones de onda no homogéneas [5]

Ecuación nº 1.3

$$\nabla^2 \vec{E} - \mu\epsilon \frac{\partial^2 \vec{E}}{\partial t^2} = \nabla \left(\frac{\rho_f}{\epsilon} \right) + \mu \frac{\partial \vec{J}}{\partial t}$$

$$\nabla^2 \vec{B} - \mu\epsilon \frac{\partial^2 \vec{B}}{\partial t^2} = -\mu \nabla \wedge \vec{J}$$

En su forma más general, describen el comportamiento de la señal electromagnética en campos dependientes del tiempo, transitorios, etc. Considerando campos armónicos y definiendo ω como su frecuencia angular:

Ecuación armónica de Helmholtz

Ecuación nº 1.4

$$(\nabla^2 + k^2)\Psi = 0$$

$$\Psi = \mathbf{E}, \mathbf{B}$$

Determinante en esta ecuación es el número de ondas k , parámetro complejo cuya parte real indica la atenuación que sufre la señal en el medio y su parte imaginaria el defasaje, tal como se obtienen a continuación:

Ecuación nº 1.5

$$k^2 = \omega^2 \mu\epsilon - j\omega\mu\sigma$$

$$k = \alpha - j\beta$$

$$\alpha = \frac{1}{\sqrt{2}} \omega \sqrt{\mu\epsilon} \sqrt{\pm 1 + \sqrt{1 + \left(\frac{\sigma}{\omega\epsilon}\right)^2}}$$

$$\beta = \frac{1}{\sqrt{2}} \omega \sqrt{\mu\epsilon} \sqrt{\pm 1 - \sqrt{1 + \left(\frac{\sigma}{\omega\epsilon}\right)^2}}$$

Por otra parte, la impedancia se obtiene de la relación entre los campos magnético y eléctrico, su forma más general es la que sigue [6]:

Ecuación nº 1.6

$$Z(\omega) = \frac{\vec{E}_y}{\vec{H}_z} = \frac{\omega\mu|\alpha|}{\alpha^2 + \beta^2} + j \frac{\omega\mu|\beta|}{\alpha^2 + \beta^2} = R(\omega) + j\omega X(\omega)$$

Con ello se observa que en un medio conductor como es el que proporcionan los metales k , se obtiene de forma aproximada;

Ecuación nº 1.7

$$\frac{\sigma}{\omega\epsilon} \gg 1$$

$$\sigma \approx 10^5 \div 10^6 \text{ S/m} \gg \epsilon \rightarrow k = \sqrt{-j\omega\mu\sigma}$$

$$Z(\omega) = \frac{\vec{E}_y}{\vec{H}_z} = \sqrt{\frac{\omega\mu}{\sigma}} e^{-i\frac{\pi}{4}} = R(\omega) + j\omega X(\omega)$$

Los campos defasan en cuadratura y las componentes real e imaginaria son del mismo orden de magnitud

1.3.2 Campos en las proximidades de superficies

Para fundamentar resultados posteriores, se estudia la propagación de campos electromagnéticos en la proximidad y en el inmediato interior de una superficie conductora (interfase). Para ello se toman en consideración las condiciones de contorno y de propagación en el límite de separación de los medios.

Ecuación nº 1.8

$$\mathbf{n} \cdot (\mathbf{B} - \mathbf{B}_c) = 0$$

$$\mathbf{n} \wedge (\mathbf{E} - \mathbf{E}_c) = 0$$

y se comprueba que al igual que en los campos estáticos, no hay campo eléctrico en el interior del conductor, resultando:

Ecuación nº 1.9

$$\mathbf{H}_c = \mathbf{H}_{\rightarrow} \cdot e^{-\frac{\epsilon}{\delta}(1+i)}$$

$$\mathbf{E}_c = \sqrt{\frac{\mu_c \cdot \omega}{2 \cdot \sigma}} \cdot (1+i) \cdot (\mathbf{n} \wedge \mathbf{H}_{\downarrow}) \cdot e^{-\frac{\epsilon}{\delta}(1+i)}$$

\rightarrow paralelo

\downarrow perpendicular




Figura nº 1.1 Campos en la proximidad de la superficie de un buen conductor.

Tal como se observa en la Figura nº 1.1, la disposición de los campos es tal que el campo magnético se dirige paralelo a la superficie del conductor mientras que el eléctrico lo hace de forma perpendicular, dichos campos son los que de acuerdo al principio de continuidad se presentan en el interior del conductor, con las características siguientes [7]:

- El campo magnético es de magnitud mucho mayor que el eléctrico.
- Existe una diferencia de fase en la propagación.
- Hay un decrecimiento exponencial rápido.

De este último punto se desprende que en realidad no hay propagación de onda ya que la señal decrece tan rápidamente que esta queda atenuada sin alternar onda alguna.

El factor δ se define como la profundidad de penetración y su valor indica la distancia de la superficie a la que la señal ha quedado atenuada un factor $e^{-1} = 0.368$ y desfasada un radián.

Su valor es:

Ecuación nº 1.10

$$\delta = \sqrt{\frac{2}{\omega\mu\sigma}}$$

Ver Anexo Mathcad nº 12.1 que está relacionada por el número de ondas k , cuyo valor es:

Ecuación nº 1.11

$$k = \sqrt{-j\omega\mu\sigma} \rightarrow \frac{\sqrt{2}}{2}(1-j)\sqrt{\omega\mu\sigma} = \frac{(1-j)}{\delta}$$

para materiales metálicos, tales como cobre, acero y aluminio se obtienen, distintas profundidades δ para cada material y para ciertos valores de f frecuencia y de conductividad σ (S/m) :

Tabla nº 1.2 Profundidad de penetración de los campos electromagnéticos para distintos materiales a distintas frecuencias

f	50Hz	50kHz	250kHz	1MHz
δ	mm	μm	μm	μm
Cu	9.345	295.5	132.1	66.08
Ac	29.689	938.8	419.8	209.94
Al	11.923	376.6	168.4	84.81

1.3.3 Resistencia superficial de una lámina metálica de gran espesor.-

Tomando en consideración un placa metálica de gran espesor en general 10δ o más de dimensión transversal, se puede considerar el desplazamiento de la señal electromagnética en un medio semi-infinito. Hemos visto en el anterior punto que el campo armónico se transmite mediante una función exponencial atenuada. En detalle es como sigue:

Ecuación nº 1.12

$$E_z = E_{z0} e^{-\frac{1+i}{\delta}y}$$

Para una onda que avanza hacia el interior de la placa, atenuándose un Neper y desfasándose un radian por cada unidad de profundidad δ acumulada.

Resulta interesante el cálculo de la densidad de corriente acumulada en la superficie para un ancho de placa unidad, se obtiene:

Ecuación nº 1.13

$$J_{sz} = \sigma \int_0^1 dx \int_0^{\infty} E_z dy = \sigma \int_0^{\infty} E_{z0} e^{-\frac{(1+i)}{\delta}y} dy = E_{z0} \frac{\sigma\delta}{(1+i)}$$

Consecuentemente la impedancia superficial sería

Ecuación nº 1.14

$$Z_s = R_s + iX_s = \frac{E_{z0}}{J_{sz}} = \frac{(1+i)}{\delta\sigma} = R_s(1+i)$$

La R_s resistencia superficial así definida sería a la de un conductor equivalente de longitud δ . [8]

1.3.4 Analogía para una línea de longitud infinita.-

Al estudiar valor de la impedancia de entrada de una línea de longitud infinita se observa el paralelismo entre la impedancia superficial de un medio semi-infinito al de la propagación de la señal.

En el caso general la impedancia de entrada de una línea de longitud infinita resulta:

Ecuación nº 1.15

$$Z_{ent} = \frac{Z_T + Z_0 \tanh(\alpha + i\beta)l}{Z_0 + Z_T \tanh(\alpha + i\beta)l}$$

que para $l \rightarrow \infty$ $Z_T \rightarrow Z_0$ y por tanto la impedancia de entrada se convierte en $Z_{ent} = Z_0$ igual a la impedancia característica de la línea.

Ahora bien para dicha línea en la que :

Ecuación nº 1.16

$$Z_0 = \sqrt{\frac{R + i\omega L}{G + i\omega C}}$$

Tomamos $R = C = 0$ y entonces se observa que el comportamiento de dicha línea es paralelo al que se sigue de la penetración de una señal electromagnética en un medio semi-infinito es decir:

Ecuación nº 1.17

$$Z_0 = \sqrt{\frac{i\omega L}{G}} \quad \lll \ggg \quad Z_s = \sqrt{\frac{i\omega\mu}{\sigma}}$$

Con la evidente equivalencia entre parámetro de la autoinducción de la línea con la permeabilidad del medio e igualmente el parámetro conductancia de la línea con la conductividad del medio. Esta analogía nos servirá para establecer un modelo de cuadripolos que se empleara a lo largo de estos trabajos.

1.4 Las corrientes inducidas

En el estudio pormenorizado de la propagación de ondas electromagnéticas en distintos medios, si consideramos un volumen de materia inmerso en una región en la que la inducción magnética varía con el tiempo, la relación Maxwell-Faraday demuestra que aparece un campo eléctrico inducido (corrientes inducidas); si el medio es conductor a su vez y de acuerdo con la Ley de Joule se origina una disipación de energía (calentamiento por inducción).

1.4.1 Solución analítica para los problemas de bobinas sonda detectoras de corrientes inducidas

El problema genérico para obtener una solución “cerrada” al comportamiento de una bobina sonda en las proximidades de un medio conductor, fue resuelto por C.V. Dodd y W.E. Deeds [9] de forma completa. Su estudio resuelve el problema introduciendo una espira por la que circula una intensidad $I\delta(r-r_0)\delta(z-z_0)$ (función delta) y obtenida la solución, aplicarla a una bobina física real de dimensiones adecuadas. El problema se resuelve para dos casos:

En el primero se trata de un medio plano, de material conductor con una capa de espesor finito y conductividad distinta de la del medio infinito.

En el segundo caso el medio, es un cilindro al que envuelve la bobina y que de diámetro inferior a ésta, consta de una capa exterior de espesor definido y un núcleo de conductividad distinta a la del medio infinito.

El proceso de cálculo parte de las ecuaciones generales electromagnéticas no homogénea, aplicadas al medio y considerando las condiciones frontera, para ello calcula el potencial vector magnético \vec{A}

Ecuación nº 1.18

$$\nabla^2 \vec{A} = -\mu \cdot \vec{i}_o + \mu \cdot \sigma \frac{\partial \vec{A}}{\partial t} + \mu \cdot \epsilon \frac{\partial^2 \vec{A}}{\partial t^2} + \mu \nabla \left(\frac{1}{\mu} \right) \wedge (\nabla \wedge \vec{A})$$

Determinado el potencial vector magnético para las distintas zonas de estudio con las condiciones de frontera, se está en condiciones de obtener el valor de las corrientes inducidas a partir de la ley de Ohm.

Ecuación nº 1.19

$$\vec{J} = \sigma \cdot \vec{E} = -\sigma \frac{\partial \vec{A}}{\partial t} = -j \cdot \omega \cdot \sigma \vec{A}$$

A continuación se obtiene el voltaje inducido en la bobina y de la relación con la intensidad de corriente que soporta, resulta la impedancia de la bobina.

Ecuación nº 1.20

$$Z = \frac{j\omega\pi\mu n^2}{(l_2 - l_1)^2 (r_2 - r_1)^2} \int_0^\infty \frac{1}{\alpha^5} I^2(r_1, r_2) \left\{ 2(l_2 - l_1) + \frac{1}{\alpha} [\Psi * \Phi] \right\} d\alpha$$

$$\Psi = 2 \exp \left[-\alpha(l_2 - l_1) - 2 + \left\{ \exp(-2\alpha l_2) \exp(-2\alpha l_1) - 2[-\alpha(l_2 + l_1)] \right\} \Phi \right]$$

$$\Phi = \frac{(\alpha + \alpha_1)(\alpha_1 - \alpha_2) + (\alpha + \alpha_1)(\alpha_1 + \alpha_2) \exp(2\alpha_1 c)}{(\alpha - \alpha_1)(\alpha_1 - \alpha_2) + (\alpha + \alpha_1)(\alpha_1 + \alpha_2) \exp(2\alpha_1 c)}$$

$$I^2(r_1, r_2) = \alpha^2 \int_{\alpha r_1}^{\alpha r_2} x J_1(x) dx$$

Esencialmente el valor de la impedancia depende de las constantes de integración de la ecuación diferencial aplicada en cada zona y en sus límites α_i que a su vez son función expresa de las distintas conductividades.

Ecuación nº 1.21

$$\alpha_i = \sqrt{\alpha^2 + j\omega\mu\sigma_i}$$

De los resultados anteriores, y tal como se muestran en la Figura nº 1.2, la gráfica contrasta los valores teóricos y los correspondientes a medidas sobre patrones reales, facilita las componentes de la impedancia para distintos materiales de distinta conductividad en función de la frecuencia y de la separación del entrehierro (air gap /lift-off).

Una aplicación inmediata de este método es el de la medida del espesor de una capa delgada de revestimiento sobre la superficie del medio.




Figura nº 1.2 Variación de la impedancia normalizada con el espesor de la capa (clad).




Figura nº 1.3 Variación de los valores experimentales y calculados de la impedancia normalizada con la frecuencia y el entrehierro (liffoff).

1.4.2 Estudio de una placa de espesor finito

Consideramos una placa o plancha metálica, conductora, de espesor $2a$ y ancho b , tal que $b \gg 2a$ situada en un campo magnético alternativo de intensidad H dirigido en dirección OZ , a cada lado de la placa, que ocupa un espacio transversal $-a < x < a$. Detalle en la figura




Figura nº 1.4 Corrientes inducidas en una placa de espesor finito.

Resueltas las ecuaciones de Maxwell para las condiciones establecidas se obtiene:

- La simetría del problema conduce a que todas las derivadas respecto a los ejes OY y OZ son nulas.
- Estudiando la continuidad se tiene:

Ecuación nº 1.22

$$H(x) = H_{0z} \frac{\cosh(jkx)}{\cosh(jka)}$$

$$E(x) = -\frac{\omega\mu}{k} H_{0z} \frac{\sinh(jkx)}{\cosh(jkx)}$$

Los campos $E(x)$ y $H(x)$ son transversales a la dirección de propagación eje OX y perpendiculares entre sí.

La impedancia superficial para una determinada profundidad x , resulta:

Ecuación nº 1.23

$$Z(x, \omega) = -\omega\mu \frac{\tanh(u)}{u}$$

$$\Rightarrow u = kx$$

Para el cálculo y su representación ver Anexo Mathcad nº 12.2

Mientras que la pérdida de potencia por unidad de superficie:

Ecuación nº 1.24

$$\frac{\langle P \rangle}{S} = \frac{H_{OZ}^2}{\sigma\delta} \frac{\sinh(\Psi) - \sin(\Psi)}{\cosh(\Psi) + \cos(\Psi)}$$

$$\Rightarrow \Psi = \frac{2a}{\delta}$$

En los caso límite, para $2a \ll \delta$ o lo que es lo mismo $\Psi \ll 1$

Ecuación nº 1.25

$$\frac{\langle P \rangle}{S} \approx H_{OZ}^2 \frac{1}{6} (a^2 \sigma (\omega\mu)^2)$$

En el Anexo Mathcad nº 12.3 se ofrece el cálculo y la representación de las pérdidas de potencia por efecto de las corrientes inducidas.

Mientras que en el caso de que $2a \gg \delta$ es decir $\Psi \gg 1$

Ecuación nº 1.26

$$\frac{\langle P \rangle}{S} = \frac{H_{OZ}^2}{2a\sigma\delta}$$

En este caso se define R_s como la resistencia superficial, equivalente al espesor δ por el que circula prácticamente la totalidad de la corriente inducida.

Ecuación nº 1.27

$$R_s = \frac{1}{\sigma \delta} \quad \text{En } \Omega/\text{m}^2$$

En el anexo Mathcad nº 12.2 se detalla el estudio de la variación de la impedancia de una placa de espesor finito.

Para el caso de un material ferromagnético la Ecuación nº 1.24 no puede resolverse de forma analítica ya que la permeabilidad del material no es constante una curva de μ_r puede representar la variación.

Tabla nº 1.3 Curva de magnetización

H	kA/m	0,1	1	3	5	11	15
μ_r	Adimensional	3701,3	1070,3	413,1	256,2	119,7	88,4

Se realiza el cálculo comparativo entre el modelo de ANSYS del cual se extrae el valor P_{avg} , y se calcula por medio de la Ecuación nº 1.24 el factor de pérdidas volumétricas, se obtiene la siguiente tabla comparativa en función de la frecuencia.

Tabla nº 1.4 Pérdidas volumetricas de potencia eléctrica.

f	Uds.	P_{avg} (W/m ³)	\mathcal{P}/S (W/m ³)(1)
50	Hz	1.339,8	1.339,4
500	Hz	2.239,8	4.160,5
5	kHz	3.786,9	13.156,6
50	kHz	7.697,9	41.605,0
500	kHz	10.553,2	131.566,7

1 Pérdidas calculadas mediante la Ecuación nº 1.24

1.4.3 Estudio de un cilindro

El método de ensayo por corrientes inducidas es un método no destructivo ampliamente usado en el proceso industrial de control de calidad. En general el ensayo es indicativo de incidencias en la fabricación (localización de fisuras o grietas, control de espesores, etc.) y no precisa de la obtención de datos medibles sobre parámetros específicos de la composición del material, por ejemplo la resistividad eléctrica y/o permeabilidad magnética, debido a la dificultad de diseñar un modelo del conjunto (sensor-muestra) simple. Sin embargo a partir de los iniciales estudios analíticos de Dodd and Deeds [10], las soluciones analíticas al problemas se resuelven en ecuaciones de bastante complejidad en este trabajo se parte de las soluciones propuestas por Blitz [11] y Förster para optar por su simplificación. El modelo de elementos finitos opta por la simplificación que supone el uso de los modelos de simetría axial y el empleo del elemento SOLID236 permite el uso de G.D.L combinados (AZ-VOLT), es decir, el vector potencial magnético con el voltaje, con lo que se logra una mayor fiabilidad en la continuidad entre los distintos medios usados. Por último, a partir de un sencillo montaje de una bobina concéntrica a las muestras cilíndricas, se miden las características electromagnéticas del dispositivo bajo las distintas tipos de muestra y se comparan los resultados con los modelos propuestos.

1. Teoría

Basados en los principios de las ecuaciones de Maxwell, se resuelven siguiendo a G. Fournet [6]

Se detallan las consideraciones previas del estudio de un dispositivo ideal, consistente en un cilindro envuelto por una bobina solenoide, por la que circula una capa de corriente que provoca un campo electromagnético inducido en el cilindro interior a la bobina, la longitud del dispositivo se considera infinita.

Para el cálculo analítico, se emplean coordenadas cilíndricas. Por simetría se anulan las derivadas de las funciones de (θ) y de (z)

Se aplican las ecuaciones de Maxwell en un medio idealizado: homogéneo, lineal, isótropo, estacionario y armónico.

Se considera nula la corriente de desplazamiento.

2. Condiciones de contorno

Las condiciones que se establecen idealizan los distintos dominios del dispositivo, es decir la bobina se considera una capa de corriente eléctrica con el factor de relleno igual a 1 y además no hay entrehierro (gap) entre la bobina y la probeta objeto del ensayo.

3. Componentes radiales

El campo eléctrico no es nulo pero tampoco armónico.

Ecuación nº 1.28

$$E_r(r, t) = E_r(0) \cdot e^{-\frac{\sigma}{\epsilon} t} \Rightarrow E_r(r, t) = 0$$

El campo magnético no es función del tiempo y es constante.

Ecuación nº 1.29

$$H_r(r, t) = H_r(r) \text{ y } r \cdot H_r(r) = cte \Rightarrow H_r(r) = 0$$

4. Componentes tangenciales y axiales

El campo eléctrico tangencial es función del resultado de la ecuación diferencial de segundo orden que son funciones de Bessel modificadas (o de Kelvin).

Ecuación nº 1.30

$$E_\theta(\lambda, r) = \frac{n \cdot I \cdot \lambda \cdot J_1(\lambda \cdot r)}{\sigma + j \cdot \omega \epsilon J_0(\lambda \cdot r)}$$

El campo eléctrico axial es nulo.

Ecuación nº 1.31

$$E_z(r, t) = 0$$

El campo magnético axial resulta de forma análoga al campo eléctrico tangencial una función dependiente de funciones modificadas f de Bessel

Ecuación nº 1.32

$$H_z(\lambda, r) = nI \cdot \frac{J_1(\lambda \cdot r)}{J_0(\lambda \cdot r)}$$

El campo magnético tangencial resulta nulo

Ecuación nº 1.33

$$H_{\theta}(r, t) = 0$$

5. Impedancia de propagación

Con los resultados anteriores se obtiene el valor de la impedancia de propagación dado por la siguiente ecuación:


Ecuación nº 1.34

$$Z(\lambda, r) = \frac{\lambda}{\sigma + j \cdot \omega \cdot \varepsilon} \frac{J_1(\lambda \cdot r)}{J_0(\lambda \cdot r)}$$

Para el cálculo y su representación ver Anexo 12,4


6. Distribución radial

Se obtiene la distribución radial de las componentes real e imaginaria de el campo electromagnético, se ofrece el resultado para la señal de intensidad de campo eléctrico. Se observa la falta de uniformidad de la distribución, con lo que cualquier proceso de cálculo precisaría la obtención de valores promedio. Esta distribución está además fuertemente influida por la frecuencia de operación, por lo que se hace necesario encaminar los cálculos con parámetros 'globales'. La Gráfica nº 1.1 y la Gráfica nº 1.2 (2) corresponde a una frecuencia $f = 50\text{Hz}$.




Gráfica nº 1.1 Distribución radial de Re(Hz)


(2) El lo que se sigue, se distingue Gráfica de Figura por ser la primera, la representación de los resultados de los cálculos expresados en la hoja de cálculo Mathcad.

Gráfica n° 1.2 Distribución radial de $\text{Re}(E_{jf})$.

7. Parámetros primarios

Considerando la dificultad de la medición directa de las componentes radiales electromagnéticas $E_{\theta}(r)$ $H_z(r)$, el proceso se encamina a la medida de los parámetros de la impedancia de la bobina, R (resistencia) y L (autoinducción) con el supuesto que dicho parámetro se verá afectado por la naturaleza del núcleo. Se han tomado cuatro materiales distintos y se han calculado a partir de valores de suministro para la conductividad eléctrica y la permeabilidad magnética, obteniéndose los resultados que ofrece la grafica en el caso de valores de L (autoinducción) versus $\delta(\omega)$ profundidad de penetración.

Gráfica n° 1.3 $L(\delta)$ para distintos medios.



Gráfica n° 1.4 $L(\omega)$ para distintos medios.

En ambas gráficas se muestra la influencia de la conductividad de las probetas en el resultado del parámetro de la autoinducción. En la Gráfica n° 1.4 se aprecia que los incrementos en el valor de $L(\omega)$ son mas apreciables a partir de los 10kHz.

1.4.4 Circuito equivalente

Tomando como modelo compacto una conexión en paralelo de tres impedancias, la que representa la bobina sensor, su capacidad distribuida y la impedancia del cilindro insertado en su interior se tendrían las siguientes ecuaciones

Ecuación nº 1.35

$$Z_b = R_b + i \cdot \omega \cdot L_b$$

$$Z_p = R_b \frac{1 + j \cdot \frac{\omega \cdot L_b}{R_b}}{1 + j \cdot \omega \cdot R_b \cdot C_o}$$

$$Z(\lambda, r) = \frac{\lambda}{\sigma + j \cdot \omega \cdot \varepsilon} \frac{J_1(\lambda \cdot r)}{J_0(\lambda \cdot r)}$$

Este efecto resonante es observable en la Figura nº 1.5 hacia los 8,5 MHz, gráfica que se ofrece como ejemplo y representa una limitación en las medidas en alta frecuencia en las proximidades del punto de resonancia para la bobina sonda.

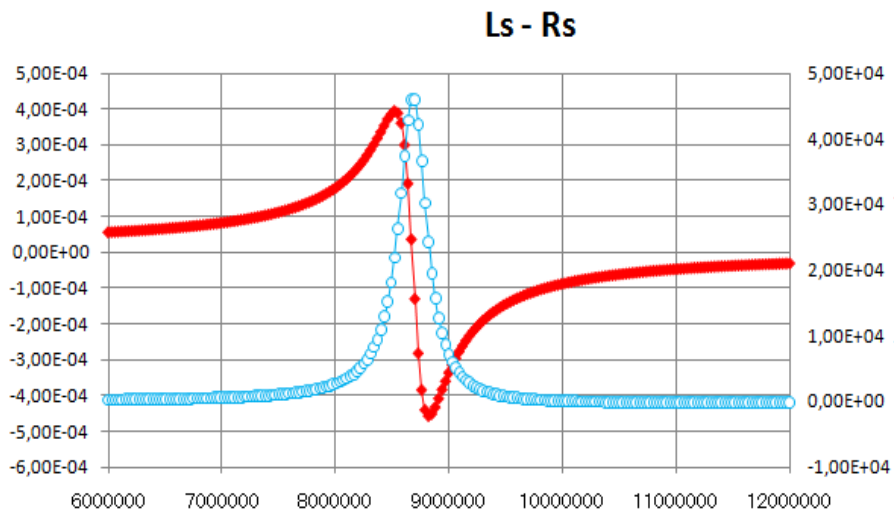


Figura nº 1.5 Frecuencia de resonancia

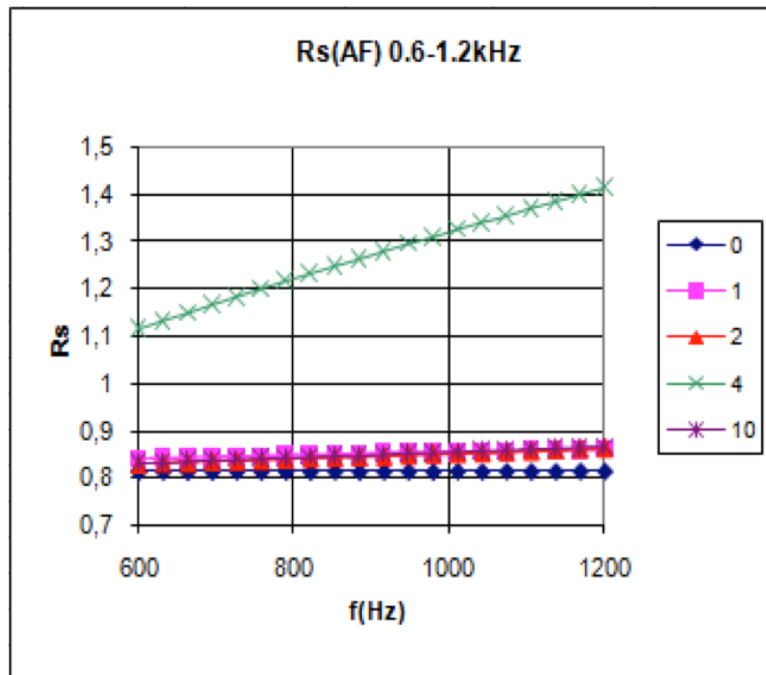


Figura nº 1.6 Resistencia vs. Frecuencia.

Se han tomado medidas en la banda 600Hz 1.2kHz de los valores de L_s y R_s para las distintas probetas, (Tabla nº 1.5). La traza de la probeta 4 que corresponde al acero magnético. F-1000, se separa del resto de materiales mostrando la enorme influencia de su permeabilidad relativa ≈ 350 . [12]

Tabla nº 1.5 Materiales de las probetas.

Material	Serie
Aire	0
Aluminio	1
Cobre electrolítico	2
Acero F-1000	3
Bronce 60/40	4

1.4.5 Modelado ANSYS

Para el modelado de ANSYS, se emplea un modelo plano axisimétrico de comportamiento electromagnético tal como el elemento Plane53. Su uso se justifica para obtener la visualización del flujo magnético en el interior de la probeta. En la Figura nº 1.7, se observa la notable redistribución de las líneas de fuerza por el efecto piel en las cercanías de la superficie de la probeta. La Figura nº 1.8 muestra el mallado 'progresivo' hacia la interface probeta-bobina. Con esta simulación no obtenemos suficientes datos para la obtención de los valores de parámetros como R y L en función de la frecuencia, utilizando el macro LMATRIX lo hace en corriente continua con lo que desaparece el efecto de las corrientes inducidas y los resultados no muestran el comportamiento real de los parámetros L y R.

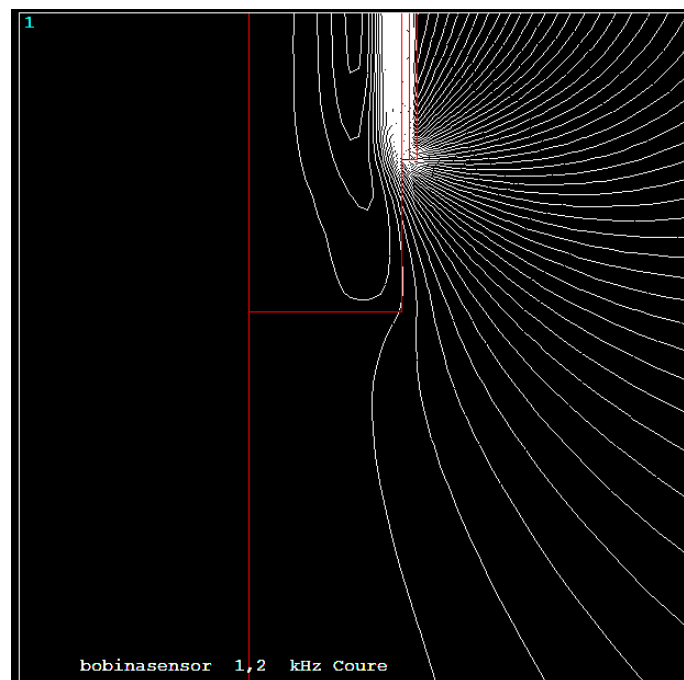


Figura nº 1.7 Distribución líneas de flujo (detalle)

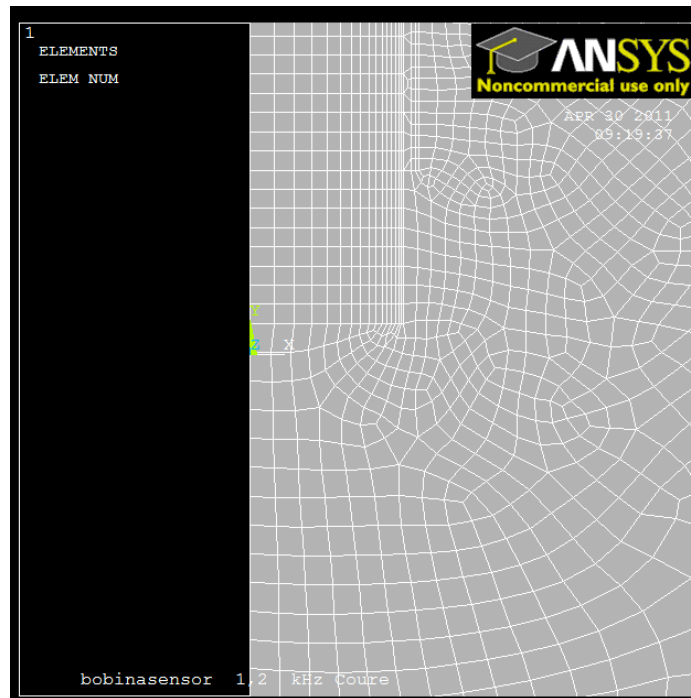


Figura nº 1.8 Mallado 2D.

Existe una cuestión adicional y es que por el método basado en los nodos (*node based*) el vector potencial magnético \vec{A} introduce errores en los contornos de los dominios de permeabilidades distintas al incumplir las ecuaciones de continuidad entre los medios.

Ecuación nº 1.36

$$\vec{B} = \nabla \wedge \vec{A}$$

Esto queda resuelto usando un elemento de volumen SOLID236 electromagnético que emplea un método basado en las aristas (*edge based*) y que posee grados de libertad para \vec{A} (potencial vector magnético y para VOLT potencial eléctrico integrado en el tiempo).

En la Figura nº 1.10 se muestra el modelo de $\frac{1}{4}$ de simetría ya mallado y en el que se alimenta la bobina en las condiciones de amplitud y frecuencia deseada, se muestran las soluciones obtenidas, la Figura nº 1.9 muestra la distribución de la densidad de corriente (incluye la inducida) en su componente imaginaria, la Figura nº 1.11, muestra a su vez la distribución de la inducción magnética pero en su componente real. La simulación nos facilita la obtención de valores de energía del campo magnético relacionado estrechamente con la inducción de la bobina, a la frecuencia de ensayo.




Figura nº 1.9 J_t 

Figura nº 1.10 Mallado 3D

Figura nº 1.11 B_s

Para la realización práctica de la experiencia, se construye una bobina solenoide e una capa con hilo esmaltado de 0.3mm de longitud 20mm y radio 5.5mm, las probetas a su vez son cilindros de 50mm de longitud y radio de 5mm, se ensayan probetas de distintas naturalezas metálicas y se resumen en cuatro clases:

Tabla n° 1.6 Características de las muestras

Material	Densidad kg/m ³	Conductividad Eléctrica MS/m	Permeabilidad Magnética relativa
Aluminio	2.700	36.2	1
Cobre electr.	8.930	57,0	1
Acero F-1000	7.876	18.2	350
Bronce 60/40	8.230	14.6	1

El equipo de medidas usado es el HP 4295A LCR impedancímetro de uso general, la medida se realiza a 2 hilos mediante el puente de 4/2 -1 conectado al PC mediante conector GPIB. El programa 4294A Data_transfer_300 administra los resultados numéricos en hojas Excel, estos datos tomados directamente desde el impedancímetro son transferidos a la hoja de cálculo convertidos en tablas y gráficos.

1.4.6 Resultados

Las medidas se realizan en la banda de 40Hz a 120kHz y con ellas se ha realizado la siguiente tabla de resultados.

Tabla n° 1.7 Valores medidos para las distintas muestras


Medida	(50Hz)		(60KHz)	Conductividad	Permeabilidad
Autoinducción	μH		μH	Teórica	Relativa
L ₀	99,60	L ₀	125,32	MS/m	
L _{cu}	99,19	L _{cu}	70,5766	57,0	1
L _{fe}	1011,24	L _{fe}	144,3738	18,2	350
L _{al}	99,49	L _{al}	71,8595	36,2	1
L _{br}	99,36	L _{br}	70,8523	14,6	1
Medida	(50Hz)		(60KHz)	Conductividad	Permeabilidad
Resistencia	Ω		Ω	Teórica	Relativa
L ₀	1,1700	L ₀	4,7703	MS/m	
L _{cu}	1,1723	L _{cu}	6,4785	57,0	1
L _{fe}	1,2066	L _{fe}	41,6012	18,2	350
L _{al}	1,1736	L _{al}	7,3741	36,2	1
L _{br}	1,1655	L _{br}	6,7890	14,6	1

Con los resultados obtenidos se realiza una comparación tomando como patrón de conductividad el cobre y se obtiene el siguiente cuadro comparativo resumen:

Tabla nº 1.8 Comparativa entre vslores medidos y teóricos

	Medido	Teórico		Diferencia	
	1,0000	1,0000	Cu	0,00%	
	21,5612	3,1319	Fe	588,4383%	
	1,5243	1,5746	Al	-3,1914%	
	3,9684	3,9041	Br	1,6470%	

El resultado implica que la medida de los parámetros L y R de la bobina usada como sensor nos suministran una buena información para de ellos calcular la conductividad del metal, en el caso del acero (Fe) esa simple medida es insuficiente y el resultado (**21.5612**) nos indica que la permeabilidad se introduce en el resultado, y obtenemos en realidad el producto ($\mu_r \cdot \sigma$). El valor de μ_r se podría obtener por un método indirecto a partir de las conductividades.

Figura nº 1.12 Autoinducción L vs. β .

tomando como variable independiente la inversa de profundidad de penetración del efecto piel


Ecuación nº 1.37

$$\beta = a\sqrt{\omega\mu\sigma}$$

En la Figura nº 1.13 se muestra la variación del defasaje de la impedancia con respecto a la frecuencia, en la que se observa que para frecuencias de 100Hz a 10kHz su dependencia con el material objeto de prueba es apreciable

Ecuación nº 1.38

$$\theta = \text{atan} \left(\frac{\text{Re}(Z)}{\text{Im}(Z)} \right)$$

Figura nº 1.13 Defasaje θ vs. Frecuencia.

1.4.7 Conclusiones

El método se muestra eficaz para la medida de la conductividad de los materiales y en el análisis de las modificaciones superficiales en la probeta (endurecimiento superficial, tratamientos térmicos) pero tiene un elemento perturbador que es la permeabilidad magnética, sobre esa característica caben algunas consideraciones. El campo magnético que genera la señal del equipo de medidas es muy débil del orden de alguna mT por lo tanto la permeabilidad medible es prácticamente con campo nulo, es decir la inicial, hay que recordar que este parámetro es fuertemente influido por la intensidad de campo magnético, y al tiempo varía con la frecuencia de la señal.

1.5 Magnetismo y cuestiones relacionadas

En se detallan fenómenos físicos relacionados con el magnetismo, el material y su estado de tensión mecánica, que informen sobre su interrelación.

1.5.1 Causas de la histéresis

Es bien conocido que si una muestra de hierro o acero, está sujeta a un trabajo (deformación en frío), las pérdidas por histéresis y la coercitividad crecen. Ver Figura nº 1.14




Figura nº 1.14 Curvas de histéresis para distintas aleaciones de hierro.

Se muestra la dependencia del ciclo de histéresis del hierro o acero endurecido mediante adición de carbono o de otro material no magnético o por deformación en frío.

Es también conocido que la adición de otros elementos no magnéticos al hierro, así como carbono en la fabricación del acero, modifica incrementando las pérdidas por histéresis y la coercitividad. Estos factores empíricos han sido conocidos y se han sugerido muchas teorías.

De esos resultados parecería que las imperfecciones, ya sea en forma de dislocaciones o de elementos impuros en el metal, causan un incremento en la pérdida de energía durante los procesos de magnetización, en la forma de una especie de fricción interna.

Otro mecanismo con el que crece la histéresis es causado por la anisotropía magneto-cristalina. Materiales ferromagnéticos con una alta anisotropía tienen una elevada histéresis.

1.5.2 Comportamiento con campos débiles: Ley de Raleigh

Si consideramos la curva de magnetización inicial, que es la variación de la magnetización con el campo obtenida cuando este es aplicado a un material ferromagnético desmagnetizado. Es Rayleigh el que en la región de campos débiles de la curva de magnetización inicial, propone la ecuación de la forma [13]

Ecuación n° 1.39

$$\mu(H) = \mu(0) + \nu H$$

la ecuación anterior conduce a la relación parabólica de la **B** inducción con el campo **H** en la curva de magnetización inicial.

Ecuación n° 1.40

$$B(H) = \mu(0)H + \nu H^2$$

De acuerdo a Raleigh el término $\mu(0)H$ representa el cambio reversible en la inducción magnética, mientras que el término νH^2 representa el cambio irreversible en la inducción magnética. Además, Rayleigh indica que el ciclo de histéresis de baja amplitud puede ser representado por curvas parabólicas las cuales tienen una permeabilidad diferencial reversible con la pendiente del bucle igual a $\mu(0)$ como muestra la figura la Figura n° 1.15.




Figura n° 1.15 Curvas magnéticas de Rayleigh.

Tomándolo en consideración y de acuerdo a la ley de Rayleigh que en la región de campo débil el ciclo de histéresis puede ser descrito por una ecuación en la forma

Ecuación nº 1.41

$$\mathbf{B} = [\mu(0) + \nu \mathbf{H}_m] \mathbf{H} \pm \left(\frac{\nu}{2}\right) (\mathbf{H}_m^2 - \mathbf{H}^2)$$

\mathbf{H}_m máximo campo del bucle

Esto conduce a dos resultados adicionales interesantes: expresiones para la pérdidas de histéresis W_H y la remanencia B_R .

Ecuación nº 1.42

$$W_H = \int \mathbf{H} \cdot d\mathbf{B} = \left(\frac{4}{3}\right) \nu \mathbf{H}_m^3$$

$$\mathbf{B}_R = \left(\frac{\nu}{2}\right) \mathbf{H}_m^2$$

1.5.3 Comportamiento en campo intenso: Ley en la proximidad de la saturación.-

En la región de campo intenso, la magnetización se aproxima a la saturación del material [14]. El primer intento de dar una ecuación, describiendo el comportamiento en esa región lo da la ley de Lamont

Ecuación nº 1.43

$$\chi = \frac{d\mathbf{M}}{d\mathbf{H}} = Cte \cdot (\mathbf{M}_s - \mathbf{M})$$

La ecuación de Lamont es tan simple como que, con campos, intensos la susceptibilidad es proporcional a las diferenciales con la saturación.

Trabajos posteriores, indican que el comportamiento con campos intensos puede ser modelado por leyes de aproximación como la dada por Becker y Döring [15].

Ecuación nº 1.44

$$\mathbf{M} = M_s \left(1 - \frac{a}{\mathbf{H}} - \frac{b}{\mathbf{H}^2} - \dots\right) + k\mathbf{H}$$


Esta ecuación expresada en formas de serie, donde el término final kH representa la magnetización forzada, que es el incremento del campo inducido en la magnetización espontánea. Generalmente es una contribución pequeña salvo para campos intensos.

1.5.4 Curva de magnetización. Modelo Frönlich- Kennelly

En los materiales ferromagnético, el comportamiento entre la densidad de campo y la inducción magnética no es lineal por tanto la permeabilidad no es constante y cualquier intento de resolver de forma analítica las ecuaciones en las que interviene μ sea imposible. Un modelo para aproximar este comportamiento lo ofrece el propuesto por Frönlich- Kennelly [16] en la que la relación entre B (inducción magnética) y H (intensidad de campo magnético) se ajusta mediante la siguiente ecuación:

Ecuación nº 1.45

$$B = \frac{H}{a + b \cdot H}$$



Gráfica nº 1.5 Curva de magnetización del acero . Modelo de Frönlich-Kennelly

Esta relación cuantitativa entre la inducción magnética y el campo magnético que la produce, es aproximada, proporcionado parámetros (a y b) constantes y que se obtiene tras analizar el comportamiento de cada material. En el caso del acero 1004 estos valores son $a = 254 \text{ A/m}\cdot\text{T}$ y $b = 0,577 \text{ 1/T}$

1.5.5 Campos magnéticos de medición

Tanto en las medidas efectuadas con el equipo Defectoscop como las del equipo HP4294A hay que considerar que la salida a tensión constante es de 0,8V y de 0,5V respectivamente lo que significa la presencia de campos débiles del orden de intensidades magnéticas, de algunas mT. El margen en frecuencias de los equipos es de 40Hz a 1MHz y de 40 a 100MHz respectivamente pero ambos se emplearan en la banda de frecuencias intermedias del orden de kHz. En ambos caso la señal es senoidal y ninguno de los equipos permite señales transitorias

2 Objetivos y planificación

2.1 Objetivos

2.1.1 Antecedentes.-

Es bien conocido la enorme difusión de los sistemas de medidas y control por corrientes inducidas, son múltiples sus aplicaciones desde la localización de grietas, hasta el control de espesores superficiales de capas de protección, se observa si embargo la prácticamente inexistencia de ensayos para determinar los espesores de dichas capas de protección, el método habitual consiste en el control a posteriori de ensayos destructivos, es por ello que pretendemos la solución a ese método estableciendo un protocolo que permita el control de espesores con métodos no destructivos. Esto facilitaría por ejemplo, la medida de espesores de capas interiores de (protección/corrosión) de tubos de transporte de vapor en servicio.

2.1.2 Planificación

La planificación de la tesis se muestra en el siguiente cronograma:

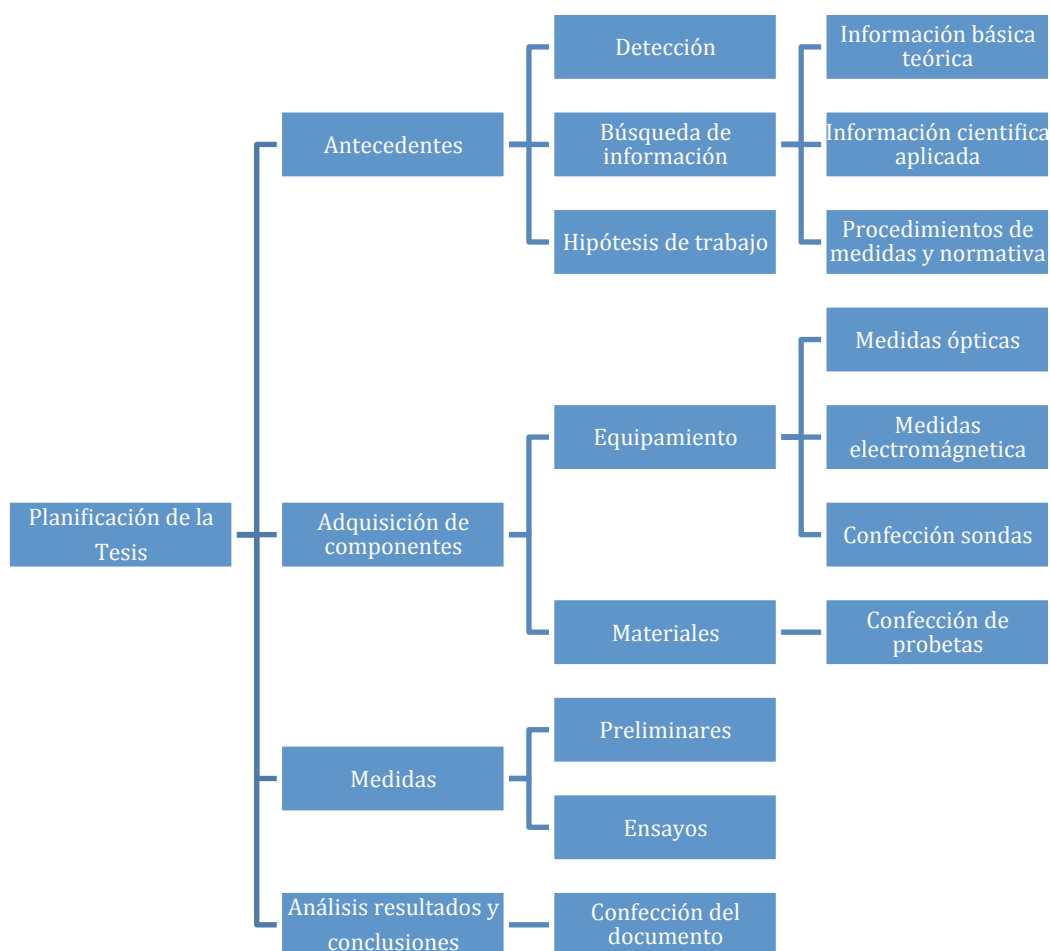


Figura nº 2.1 Objetivos y plan de trabajo

2.2 Procedimientos

A partir de la teoría expuesta, en los capítulos anteriores se concreta un procedimiento de medida para poder evaluar el espesor de las capas de protección. En primera instancia, un método “pasa-no pasa”, es decir, se establecen límites de máximos y mínimos que una vez especificados sirvan para un sencillo y rutinario sistema de control. Un segundo procedimiento para que a partir de un modelo matemático, se pueda establecer un método de medida de los espesores de las capas del material a estudiar.

2.3 Equipos de medida

De acuerdo a los criterios anteriormente expuestos, se dispone de dos equipos de medidas de impedancia, ambos medidores de impedancia pero bien diferenciados:

2.3.1 Equipo Defectoscop F140d



Figura nº 2.2 Equipo Defectoscop F140d.

El Defectoscop facilita medidas impedancia con las siguientes limitaciones:

8. La lectura se realiza a través de la pantalla donde aparece la traza correspondiente a la impedancia Z .
9. La medición de Z se realiza punto a punto a cada frecuencia f con posibilidad de escalado Δf pero no con barrido.

Realizadas las pruebas pertinentes se observa la dificultad de toma de datos con este método totalmente manual, para solventarlo se extrae la señal de voltaje a través de un conector de salida del equipo, que se introduce al equipo multímetro digital HP 34401A $\frac{1}{2}$ y se toma el registro de datos mediante el soporte informático BenchLink Datalogger.

El resultado no es satisfactorio por la imprecisión de la lectura, se comprueba el patrón y se obtiene la gráfica correspondiente, donde se aprecia que si bien el equipo resulta adecuado para las pruebas de corrientes inducidas de control de defectos, grietas, etc. donde no resulta de interés la lectura absoluta, ya que la medida se realiza sobre comparación de patrones, no es útil donde en cambio se precise precisión en la medida ver calibrado en anexo .

Por esta causa y por la imposibilidad de realizar barridos de frecuencia se descarta su uso y se emplea el equipo Agilent HP 4294 A que no ofrece estas dificultades.



Figura nº 2.3 Multímetro digital hp 34401A $6^{1/2}$.




Figura nº 2.4 Montaje y conexiones equipo Defestoscop F140d

2.3.2 Equipo HP 4294 A

El equipo de medidas usado, el HP 4294 A es de uso general y mide todas los parámetros componentes de la impedancia: R resistencia eléctrica en (Ω ohmios), la reactancia inductiva $X = \omega \cdot L$ (Ω ohmios) de donde deduce la L autoinducción (H henrios), aunque no se hará uso de ellas, por no intervenir en el método de medidas ofrece lecturas de la componente G (S siemens) y de la reactancia capacitiva $X_c = \omega \cdot C$ de la que se deduce la capacidad C (F faradios).




Figura nº 2.5 Equipo Agilent hp 4294A.

El equipo se constituye en un puente equilibrado de Wheatstone, que mide a dos o cuatro hilos, su precisión es extrema y queda mostrado en la gráfica de la F que muestra el campo de precisión de acuerdo a la magnitud de los parámetros medidos.




Figura nº 2.6 Ejemplo de precisión en la medida indicado en la carta de reactancias.




Figura nº 2.7 Montaje y conexiones equipo de medida HP 4294A.

El equipo puede funcionar en local, programado, programado exterior desde un disquete y también como se ha usado en todos los ensayos, mediante una conexión GPIB-USB que conecta el equipo a un portátil convencional, lo que permite a su vez el control remoto desde la red.

Se ha empleado un soporte informático mediante el uso de un programa que emplea una hoja de cálculo Excel, los macros de dicho programa libre han sido modificados, adecuándolos para nuestro uso. En el Anexo HHH se muestra parcialmente una hoja.

Se han confeccionado bobinas de distintos tipos , para conocer su influencia en las medidas sobre la superficie de las placas, una bobina de construcción convencional, bobinas de una capa, bobinas planas, aunque la que mejor resultado ofrece es la bobina diferencial que se emplea en el Defectoscop para su uso ha habido que conectarla al accesorio de entrada al equipo mediante conectores tipo schuko a 6 hilos

2.3.3 Dispositivos.-

El equipo Defectoscop está dotado de sondas de medida absoluta y diferencial, sin embargo HP 4294A funciona con terminales a cuatro hilos (transformadores) y a dos (puente de Kelvin) por lo que se confeccionan sondas de prueba a dos hilos y a cuatro.




Figura nº 2.8 Sonda diferencial.

Esquemas

Se muestran tres de las posibilidades que ofrecen las sondas de medición




Figura nº 2.9 Distintos tipos de bobinas sonda.

10. Absoluta

Constituidas por un solo devanado, son sensibles a la respuesta de todos los cambios en el material, tratamientos térmicos, forma, etc. Los cambios de naturaleza gradual son detectados, tales como discontinuidades abruptas.

11. Diferencial

Las probetas con dos o más devanados compensados, Están diseñadas para responder selectivamente a los cambios abruptos en la pieza tales como, por ejemplo grietas, son insensibles a los cambios suaves del material o de la geometría y con defectos grandes y continuos. En el caso de ser usadas para la ordenación de material o con propósitos de comparación los núcleos se separan con una carga en la parte “desconocida” mientras que la otra está emplazada sobre la “conocida” o patrón.

12. Reflexión

Son bobinas en las que el sensor (pick-up) está cerca de la pieza de prueba y detecta las corrientes inducidas que se reflejan desde ella. Estas sondas son usualmente diferenciales, pero pueden ser absolutas, con una bobina equilibrada situada lejos de la pieza de prueba, bien en sus alrededores, o adyacente a ella, una bobina emisora similar sirve para asegurar el equilibrio. Su principal ventaja es un gran ancho de banda y una buena relación señal ruido.

2.3.4 Conexión USB/GPIB

Esta conexión se emplea para el enlace entre la salida de datos del impedancímetro y la entrada USB al portátil, y para la conexión del equipo de medidas a la red para abrir la posibilidad de control remoto. Al mismo tiempo soporta la comunicación del programa de gestión del equipo de medidas para su programación.



Figura nº 2.10 Conector USB/GPIB enlace del impedancímetro al ordenador para adquisición de datos

3 Métodos numéricos

3.1 Introducción

En los ensayos de corrientes inducidas, el parámetro más importante a la hora de obtener resultados que informen sobre el medio y sus características dimensionales, por ejemplo espesores, grietas, etc. o sus características magnetoeléctricas, permeabilidad magnética y/o conductividad eléctrica, es la impedancia de la bobina sonda. La posibilidad de obtenerla a partir de la Ecuación nº 1.20 y de sus derivadas, implica el cálculo de las ecuaciones analíticas que allí se desarrollan, incluidas integrales definidas con límite infinito. El modelo analítico para el cálculo de la impedancia de la bobina sonda en distintas geometrías de los medios de prueba son inicialmente presentados por Dodd and Deed. [17]

Las soluciones obtenidas han sido aplicadas para resolver el cálculo de las corrientes inducidas por la bobina sensor en distintas geometrías del medio objeto de estudio, tales como plano semi-infinito, placas de espesor variable, plano multicapas, cilindros tubos, etc. También para modificaciones de los parámetros electromagnéticos permeabilidad (chapas de transformadores) y conductividad (superficies en capas endurecidas) el cambio en la impedancia debido a alteraciones del medio, grietas, ranuras, roblones, etc. Estudios recientes, abarcan geometrías esféricas o bien se sirven de funciones integrales trascendentes. En el estudio presente y después de distintas alternativas se ha optado por un método de desarrollo en series para obtener los resultados de un modo fiable y rápido. Se confeccionan programas para la hoja de cálculo MATHCAD, donde a partir de las ecuaciones diferenciales y con las condiciones de contorno exigidas resultan expresiones en forma integral como la Ecuación nº 1.20 en su forma cerrada de cálculo directo, se sustituye por el empleo de desarrollos en series, que representan la ventaja de ser un cálculo mas sencillo y rápido.

3.2 Desarrollo en series

Consideramos una bobina con núcleo de ferrita de sección transversal rectangular, situada sobre un semiespacio conductor y magnético de conductividad σ y permeabilidad μ . La geometría es la de la Figura nº 3.1 donde se muestra la zona de integración.

Una cuestión importante del análisis presentado por Dodd es la de que a frecuencias convencionales asemeja la distribución real de las corrientes en un devanado con la de hojas de corriente equivalentes y entonces los campos electromagnéticos calculados para una única espira se obtienen por superposición.

La impedancia de la bobina aislada de cualquier medio, se calcula y considerando la simetría axial de que goza el problema resulta una expresión donde ω es la frecuencia angular, N es el número de espiras, I la corriente de excitación (supuesta constante en toda la sección transversal) y A_ϕ es el único componente del potencial vector magnético.

Ecuación nº 3.1

$$Z = \frac{j\omega 2\pi}{I} \frac{N}{area} \iint_{area} r A_{\varphi} dr dz$$




Figura nº 3.1 Modelo de prueba de corrientes inducidas sobre una placa de acero, en blanco zona de integración

La impedancia de la bobina en el ensayo, puede ser considerada como la suma de la impedancia al aire Z_0 y el cambio de impedancia producido por el efecto de las corrientes inducidas en el semiespacio conductor ΔZ .

Ecuación nº 3.2

$$Z_0 = \frac{j\omega 2\pi \mu_0 N^2}{(r_2 - r_1)^2 (z_2 - z_1)^2} \sum_{i=1}^{\infty} \frac{Int^2(q_i r_1, q_i r_2)}{q_i^5} \left\{ \frac{2[q_i(z_2 - z_1) - 1 + q_i(z_1 - z_2)]}{[(q_i b) J_0(q_i b)]^2} \right\}$$

Ecuación nº 3.3

$$\Delta Z = \frac{j\omega \pi \mu_0 N^2}{(r_2 - r_1)^2 (z_2 - z_1)^2} \sum_{i=1}^{\infty} \frac{Int^2(q_i r_1, q_i r_2)}{q_i^5} \frac{[\exp(-q_i z_1) - \exp(-q_i z_2)] q_i \mu_r - p_i \mu}{[(q_i b) J_0(q_i b)]^2 q_i \mu r + p_i}$$

En las que:

Ecuación nº 3.4

$$\text{Int}(x_1, x_2) = \int_{x_1}^{x_2} x J_1(x) dx \text{ y el parámetro } p \text{ es [18] :}$$

Ecuación nº 3.5

$$p = \sqrt{q^2 + j\omega\mu_0\mu_r\sigma^2}$$

siendo $J_1(x)$ la función de Bessel de primera especie y orden 1, mientras que el parámetro de integración se calcula para cada zona i mediante la Ecuación nº 3.1 y la Ecuación nº 3.2 han sido obtenidas asumiendo una solución en la región infinita ($b \rightarrow \infty$). En la serie propuesta como método de desarrollo en serie (*series expansions method*), la región en la que se busca la solución es considerada finita en la coordenada radial ($0 \leq r \leq b$). Siguiendo la separación de variables y la imposición de una condición homogénea de Dirichlet, condición de contorno, para el campo magnético en $r = b$ la expresión general para el potencial vector magnético resulta [19]

Ecuación nº 3.6

$$A_\varphi(r, z) = \sum_{i=1}^{\infty} J_1(q_i r) [C_i \exp(-p_i z) + D_i \exp(-p_i z)]$$

Donde ahora p_i se obtiene a partir de la Ecuación nº 3.7 para cada q_i :

Ecuación nº 3.7

$$p_i = \sqrt{q_i^2 + j\omega\mu_0\mu_r\sigma^2}$$

Mientras que los **eigenvalores** (valores propios) discretos están calculados para la ecuación:

Ecuación nº 3.8

$$J_1(q_i b) = 0 \rightarrow J_1(x_i) = 0 \rightarrow q_i = \frac{x_i}{b}$$

Los valores que hacen cero las funciones de Bessel se obtienen en tablas del Handbook [20], Ver Anexo Mathcad nº 12.8 ya que en la hoja de cálculo de Mathcad se introducen como una matriz de datos ya resuelta.

Los coeficientes de desarrollo desconocidos C_i y D_i son calculados aplicando las condiciones de contorno en la interfaz de las subregiones de la geometría del problema y usando las propiedades de ortogonalidad de las funciones de Bessel [7]

Calculado el potencial vector magnético a partir de la Ecuación nº 3.6 para los auto valores obtenidos a partir de las condiciones definidas en las raíces de los ceros en la ecuación de Bessel, se obtienen las siguientes expresiones para los valores de impedancia:

Ecuación nº 3.9

$$Z_o = \frac{j\omega 2\pi\mu_0 N^2}{(r_2 - r_1)^2 (z_2 - z_1)^2} \int_0^\infty \frac{Int^2(qr_1, qr_2)}{q^5} \left\{ (z_2 - z_1) + \frac{\exp[-q(z_2 - z_1)] - 1}{q} \right\} dq$$

Ecuación nº 3.10

$$\Delta Z = \frac{j\omega\pi\mu_0 N^2}{(r_2 - r_1)^2 (z_2 - z_1)^2} \int_0^\infty \frac{Int^2(qr_1, qr_2)}{q^6} \left[\exp(-qz_1) - \exp(-qz_2) \right]^2 \frac{q\mu_r - p}{q\mu_r + p} dq$$

Mathcad nº 12.6 para una bobina de dimensionado y geometría concretos.

3.3 Aspectos del cálculo

Las ventajas del desarrollo en series, consisten en el hecho de que el rango de integración ha sido convertido en una serie de valores discretos. Si las rutinas automáticas de integración son usadas para superar el problema de la truncación y al mismo tiempo preservar el nivel de exactitud en el cálculo, el proceso se ralentiza al integrar por separado las partes real e imaginaria. En el proceso de integración los puntos en los que el integrando es evaluado no son conocidos de antemano y así no hay términos que puedan ser pre-calculados.

Por otra parte, en la Ecuación nº 3.9 y la Ecuación nº 3.10 sólo se fija el parámetro b con lo que se sigue prácticas similares usadas en métodos numéricos. La aproximación por series es un método de cálculo muy rápido, ya que no sólo los valores propios q_i sino otros términos pueden ser pre calculados. En concreto la Ecuación nº 3.6 para un estudio paramétrico con una bobina específica, sólo depende de los valores r_1 y r_2 , y su valor puede obtenerse previamente al proceso de suma de términos, sin que dependa de otros valores como la separación de entrehierro (lift-off), y la conductividad y permeabilidad del medio material. Así será especialmente útil al intentar obtener un número elevado de soluciones para los valores de la impedancia a distintas frecuencias (barrido).

Los parámetros de la bobina son:

$$r_1 = 6 \text{ mm}, r_2 = 7 \text{ mm}, z_1 = 0,5 \text{ mm}, z_2 = 30 \text{ mm} \quad \mu_r = 1 \quad \sigma = 56 \text{ MS/m}$$

Los parámetros del medio $\sigma = 16.45 \text{ S/m}$.

En la tabla siguiente se muestra el valor de los parámetros de impedancia calculados a distintas frecuencias para la bobina sonda.

Tabla nº 3.1 Impedancia vs. Frecuencia.

f		Zo		Re		-Im		Re(Z)		Im(z)	
			uds		uds		uds		uds		uds
1	Hz	10,578	mΩ	15,012	mΩ	1,096	μΩ	15,012	mΩ	10,577	mΩ
5	Hz	52,889	mΩ	336,989	mΩ	53,934	μΩ	336,989	mΩ	52,835	mΩ
10	Hz	105,778	mΩ	1,242	Ω	271,463	μΩ	1,242	Ω	105,507	mΩ
50	Hz	528,890	mΩ	22,000	Ω	9,678	mΩ	22,000	Ω	519,212	mΩ
100	Hz	1,058	Ω	68,147	Ω	40,380	mΩ	68,147	Ω	1,018	Ω
500	Hz	5,289	Ω	626,305	Ω	754,182	mΩ	626,305	Ω	4,535	Ω
1	kHz	10,578	Ω	1,320	kΩ	2,186	Ω	1,320	kΩ	8,392	Ω
5	kHz	52,889	Ω	5,024	kΩ	17,763	Ω	5,024	kΩ	35,126	Ω
10	kHz	105,778	Ω	8,025	kΩ	39,523	Ω	8,025	kΩ	66,255	Ω
50	kHz	528,892	Ω	21,002	kΩ	225,890	Ω	21,002	kΩ	303,002	Ω
100	kHz	1,058	kΩ	30,798	kΩ	465,543	Ω	30,798	kΩ	592,457	kΩ
500	kHz	5,289	kΩ	72,234	kΩ	2,420	kΩ	72,234	kΩ	2,869	kΩ
1	MHz	10,578	kΩ	103,304	kΩ	4,884	kΩ	103,304	kΩ	5,694	kΩ

Para observar la influencia del tipo de sonda se realizan cálculos para una sonda de iguales dimensiones pero construida con un calibre de hilo $r_1 = 6$ mm, $r_2 = 7$ mm, $z_1 = 0,5$ mm, $z_2 = 30$ mm $\mu_r = 1$ $\sigma = 56$ MS/m

Tabla nº 3.2 Variación de la Impedancia vs frecuencia.

f	uds	Z_0	unidades	$\Delta Z(\text{Re})$	unidades	$\Delta Z(\text{Im})$	unidades	ΔL_s	L_s	unidades
50	Hz	20.410	m Ω	0.360	m Ω	0.243	m Ω	0.772	64.207	μH
100	Hz	40.828	m Ω	0.972	m Ω	0.863	m Ω	1.378	63.606	μH
1	kHz	408.278	m Ω	12.941	m Ω	29.210	m Ω	4.649	60.330	μH
50	kHz	20.410	Ω	0.174	Ω	2.464	Ω	7.843	57.136	μH
100	kHz	40.828	Ω	0.253	Ω	5.040	Ω	8.021	56.958	μH
500	kHz	204.139	Ω	0.589	Ω	25.948	Ω	8.260	56.720	μH
1	MHz	408.278	Ω	0.840	Ω	52.252	Ω	8.316	56.663	μH

Las columnas Z_0 (imaginario puro) e ΔZ (complejo) se han calculado aplicando las fórmulas de la Ecuación nº 3.8 y de la Ecuación nº 3.9 y las autoinducciones a partir de Z .

Ecuación nº 3.11

$$Z = Z_0 + \Delta Z$$

Ecuación nº 3.12

$$L_s = \frac{\text{Im}(Z)}{\omega}$$

Los resultados obtenidos con el método integral se muestran en el Anexo Mathcad nº 12.6 las integrales son calculadas por Mathcad por métodos de cuadratura adaptativos tomando una precisión del 0,01% .

Por otra parte la convergencia numérica de las series puede ser aceleradas usando técnicas sofisticadas, tales como el algoritmo de Wynn-Epsilon, en particular el método proporciona un algoritmo eficiente por la aplicación de la transformación en la forma [21]

Ecuación nº 3.13

$$T(S_n) = \frac{S_{n+1}S_{n-1} - S_n^2}{S_{n+1} - 2S_n + S_{n-1}}$$

La simple observación del sumatorio de términos nos muestra que la convergencia es más rápida para la componente real y para altas frecuencias, por el contrario más términos son necesarios para mayores contornos (valores de b).

4 Simulación ANSYS

4.1 Introducción

La impedancia de la bobina usada en los ensayos no destructivos por corrientes inducidas, es el parámetro fundamental para el conocimiento del fenómeno. Sabemos que pequeñas variaciones en el dimensionado o características del medio, son rápidamente reflejadas como alteraciones en la medida de la impedancia. Se ha visto el desarrollo matemático del fenómeno y ahora se trata el problema inverso [22]; a partir de unos condicionantes físicos, establecer un modelo que los simule.

La solución analítica del problema de las corrientes inducidas sólo, es posible en un número reducido de caso con una formulación fácil, con una geometría sencilla y con materiales de características homogéneas, El programa ANSYS emplea básicamente variantes de método general de resolución de ecuaciones diferenciales parciales, como es el método de elementos finitos,[23] en este método, el cálculo se efectúa por cada elemento que se obtiene después del mallado de la geometría objeto de estudio, por tanto, ofrece una mayor posibilidad de resolver el problema inverso, es decir a partir de una geometría, y de unas fuentes de campos electromagnéticos, obtener el campo resultante. Hay que considerar los distintos tipos de fenómenos físicos que se dan en la producción de corrientes inducidas, así un campo contante o fenómenos estáticos no alterarán el medio y no resultan corrientes inducidas. El fenómeno debes de ser transitorio y/o armónico, Por otro lado el medio debe de ser conductor, aunque la distribución del campo electromagnético, ocupe el resto de medios, no conductores, vacío, etc. Una característica peculiar de la aplicación del cálculo por elementos finitos, es la existencia en general de frontera o límite infinito como el medio que envuelve el dispositivo que se analiza y que interviene en el cálculo.

Con el fin de obtener la mayor información posible sobre la cuestión de la propagación de señal en medios conductores, con la consiguiente aparición de las corrientes inducidas, se analizan los distintos elementos que proporciona el programa Ansys. Una primera estimación se puede realizar empleando elemento electromagnéticos bidimensionales lo que exige una simetría respecto al eje Z. El elemento PLANE53 proporciona las prestaciones exigidas para el cálculo.

Por sus limitaciones, principalmente la exigencia de modelos planos y simétricos en el eje Z y por presentar mejoras substanciales en el cálculo electromagnético se propone un modelo tridimensional mediante el uso del elemento SOLID236.

4.2 Modelo plano

Se realiza un modelo plano en el que se refleja la proporcionalidad de las capas de protección. Se somete la superficie en contacto a un campo magnético transversal y se observa el comportamiento y la distribución en el interior de las capas de protección de forma intuitiva se observa la disminución de la zona 'afectada', y por lo tanto, que proporcione información de los parámetros, distribución espacial, etc., con la frecuencia

de manera que será el factor decisivo en la decisión de elegir las frecuencias de observación.

Las Figura nº 4.1 y Figura nº 4.2 representan la distribución de líneas de fuerza del flujo magnético, la Figura nº 4.3 y la Figura nº 4.4 representan la distribución del valor del potencial magnético vectorial AZ, en este modelo la dirección del vector es la positiva del eje Z.

Las Figura nº 4.6 y Figura nº 4.7, representan la distribución espacial de la densidad de corriente total (incluidas las corrientes inducidas).

En cada pareja la primera figura corresponde a una campo magnético alterno de 50Hz, mientras que la segunda el campo magnético de igual intensidad es de 5kHz. Es apreciable la concentración de las magnitudes magnetoeléctricas en un espesor de profundidad que disminuye con la frecuencia.

Esta simulación emplea una macro **HMAGSOLV** que resuelve las ecuaciones básicas en los nodos y adicionalmente emplea también una macro **POWERH**. Ambas dan resultados de salida para todas las magnitudes manejadas en el modelo. Sin embargo los parámetros como la autoinducción han de ser calculados a posteriori, ya que el programa sólo lo realiza en modelos magnetostáticos.

La Figura nº 4.5 es el modelo plano en el que se representa una sección de la chapa A1, la capa de anclaje A2, la de protección A3 y la de la bobina A4, los espesores de las capas A2 y A3 son de 100 y 400 μm .

El modelo a supuesto las siguientes propiedades materiales:

Tabla nº 4.1 Características de los materiales.

Material		Resistividad	Permeabilidad
Acer	Acero J250 para tuberías de presión	$\rho = 2,00\text{E-}07\Omega\text{m}$	$\mu_r = 1,000$
Coure	Cobre electrolítico	$\rho = 1,72\text{E-}08\Omega\text{m}$	$\mu_r = 1,000$
AcerCrNi	Aleación de anclaje de Cr Ni	$\rho = 7,20\text{E-}07\Omega\text{m}$	$\mu_r = 1,008$
Alenial	Aleación de protección Ni Al	$\rho = 1.50\text{E-}08\Omega\text{m}$	$\mu_r = 1,029$




Figura nº 4.1 Líneas de campo a 50Hz.




Figura nº 4.2 Líneas de campo a 50 kHz.




Figura nº 4.3 Az 50 Hz.



Figura nº 4.4 Az 50 kHz.




Figura nº 4.5 Dimensionado capas de protección.




Figura nº 4.6 J_t 50 Hz (vectorial).




Figura nº 4.7 J_t 50 kHz (vectorial).

4.3 Modelo tridimensional

Las limitaciones con las que se encuentra el cálculo de elementos finitos usando elementos planos para resolver problemas con modelos tridimensionales, son las que se exige una exacta simetría axial en el modelo y en las fuentes de energía, con lo que sólo unos pocos casos pueden ser resueltos. Para un modelo más general se deben de emplear elementos tridimensionales para problemas electromagnéticos, en los que se estudian campos armónicos, se puede usar el elemento SOLID236. En modelo plano se suponen infinitas las dimensiones longitudinales del modelo (bobina de longitud infinita) y el resultado siempre será aproximado al modelo real de longitud finita, en el modelo tridimensional, en cambio, el modelo reproduce exactamente las dimensiones de la bobina y aprovechando la simetría radial sólo se estudia $\frac{1}{4}$ del modelo, en la que la placa se dimensiona de manera que no influya el efecto frontera.

4.3.1 Solid236

El elemento SOLID236, es un elemento 3-D con veinte nodos y con capacidad para modelar campos electromagnéticos. Tiene grados de libertad magnéticos y eléctricos y está basado en la formulación de flujo en las aristas (edge-flux). La formulación en lugar de usar los nodos como punto de cálculo, integra los resultados a lo largo de las aristas del elemento, lo que proporciona soluciones que con métodos anteriores son inviables por inexactas.

La formulación emplea un árbol de contraste (tree gaugin) para obtener una solución única al problema. Parte pues de la premisa del cálculo de potencial vector magnético y de resolver las ecuaciones mediante la condición de contraste (gauge) de Coulomb [7]. El grado de libertad AZ del flujo en las aristas, es la integral en línea del potencial vector magnético a lo largo de las aristas del elemento. Es decir, el cálculo no se realiza en los nodos como es habitual.




Figura nº 4.8 Elemento SOLID236.

En la figuras siguientes se muestra las características del elemento, en las que se aprecian los 12 nodos intermedios sobre las 12 aristas, que se suman a los 8 nodos sobre los vértices del tetraedro.

En la Figura nº 4.9 se representa el mallado mediante el uso de elemento hexaedro en forma de cubos regulares, debido a su simetría radial se usa sólo un cuarto de la representación.




Figura nº 4.9 Mallado 3D hexaédrico.




Figura nº 4.10 Volumen elemento entorno




Figura nº 4.11 Detalle entorno bobina placa.

La Figura nº 4.10 representa el mallado completo del modelo, para mejorar la exactitud en la resolución del problema, el entorno del conjunto bobina placa se rodea con medio aire, y se usa el elemento tetraedro, con ajuste refinado en las proximidades de las superficies interfaz entre zonas, detalle en la Figura nº 4.11, se condicionan las caras del cubo exterior con condiciones de contorno infinito, y las caras de simetría con la condición de continuidad de los medios.




Figura nº 4.12 Distribución de la Inducción,




Figura nº 4.13 Campo magnético vectorial.

La Figura nº 4.12 representa la distribución del campo magnético en el modelo propuesto, se observa un mayor gradiente de potencial magnético (zona roja) en la separación entre la bobina y la placa (entrehierro).

La Figura nº 4.13 muestra a su vez la distribución en magnitud y dirección del vector magnético densidad de campo o inducción magnética, en la que se observa la alta concentración de intensidad de campo en el eje de simetría.




Figura nº 4.14 Densidad de corriente.




Figura nº 4.15 Densidad de corriente (vectorial).

La Figura nº 4.14, muestra la distribución de corriente total en el modelo. Se observa el efecto de proximidad (skin) en las capas radiales de la bobina y también la zona que ocupan las corrientes inducidas en las placas y en las cercanías de la bobina. En la Figura nº 4.15, se obtiene la misma distribución pero mostrando la representación vectorial del parámetro J_{tot} . Por último se ofrece un detalle de la distribución de las corrientes inducidas en la placa en la Figura nº 4.16.




Figura nº 4.16 Distribución de J_t superficial a la placa.




Figura nº 4.17 Distribución transversal 2D líneas de fuerza magnética.

Se añade para una mejor visualización del modelo una imagen en 2D de distribución de las líneas magnéticas que representan el flujo magnético, esta representación no es posible usando elementos 3D [24].

4.3.2 Resultados numéricos

El programa ANSYS además de la información gráfica, facilita “macros” que resuelven subrutinas de cálculo y ofrecen resultados para determinados parámetros electromagnéticos del modelo, en concreto analizamos **SENERGY** y **POWERH**, el primero calcula la energía almacenada en los distintos componentes del modelo, y lo hace partir de la suma de elementos. Esta energía está relacionada con parámetros del modelo como es la autoinducción de la bobina, que se obtiene de forma indirecta ya que el macro LMATRIX que utiliza ANSYS para su obtención, sólo lo hace con campos estacionarios. En nuestro caso con campos armónicos se puede obtener mediante cálculo adicional.

Ecuación nº 4.1

$$P = 1/2 (\vec{E} * \vec{D} + B * \vec{H})$$

En el modelo que se estudia se considera nula la corriente de desplazamiento por lo que el producto $\vec{E} * \vec{D}$ es nulo.

Tabla nº 4.2 Resultados pérdidas de potencia modelo ANSYS.

	Vol	Nº elementos	$\mu_r = 200$	$\mu_r = 150$	25%
Pérdidas de potencia	Total		8.881,60	8.929,59	-0,540%
Energía almacenada	1	1.875	0,78548	0,93469	-18,996%
Energía almacenada	2	520	1,3959E+01	1,3847E+01	0,802%
Energía almacenada	3	25.132	3,1135E+01	3,0908E+01	0,729%
Energía almacenada	Total	27.258	4,5880E+01	4,5569E+01	0,678%

En la Tabla nº 4.2, se ofrecen los resultados de ANSYS para el cálculo de los parámetros de energía. En la fila Pérdidas de potencia, es la energía perdida debido a las corrientes inducidas o de Foucault, ver Anexo

para una permeabilidad relativa de 200 y 150, con lo que la tercera columna de porcentajes (%) es la variación porcentual entre los dos casos, filas 1,2 y 3 de energía almacenada se calcula para cada componente del modelo 1 placa, 2 bobina, y 3 entorno. En la columna nº de elementos, se indica su número por componente, Se observa que una disminución de la permeabilidad del -0.540% representa una disminución del -18.996% de las pérdidas calculadas para la placa, lo que muestra la clara influencia que tienen las características del medio con la aparición y la magnitud de las corrientes inducidas.

Tabla nº 4.3 Cálculo comparativo de pérdidas.

	Vol	Nº elementos	$\sigma = 6.6E+06$ S/m	$\sigma =$ 8.325E+06 S/m	25%
Pérdidas Potencia	Tot		8.881,60	9.0139,32	-1.490%
Energía almacenada	1	1.875	0,78548	0,82184	-5.011%
Energía almacenada	2	520	1,3959E+01	1,3951E+01	0,330%
Energía almacenada	3	25.132	3,1135E+01	3,1105E+01	0,270%
Energía almacenada	Tot.	27.258	4,5880E+01	4,5832E+01	0,198%

En la Tabla nº 4.3 se observa la variación de las energías calculadas por ANSYS al variar la conductividad del medio un 25%, de nuevo se observa como la respuesta máxima la da el elemento metálico placa a pesar de no ser el componente que almacena mas energía.

5 Modelo de cuadripolos

5.1 Introducción

Se ha observado en el apartado 1.3.4 el paralelismo entre la propagación de una señal armónica a través de una línea de transmisión de parámetros distribuidos y a su vez la relación con la propagación de una señal electromagnética a través de un medio semi-infinito. Considerando los parámetros primarios de un cuadripolo se tiene:




Figura nº 5.1 Representación de un modelo cuadripolar.

- Z_0 Es la Impedancia característica del cuadripolo
- Γ_0 Es el Parámetro de transmisión
- Z_e Es la Impedancia de entrada
- Z_T Es la Impedancia terminal

Aceptada la característica de la red cuadripolar para servir de modelo a las capas sucesivas objeto de estudio, asumimos la simplificación de que las variables sobre los ejes transversales se consideran no diferenciables, además de ignorar las reflexiones de las superficies límite entre los distintos medios, considerándolas de efectos despreciables.

Con este caso concreto, se estudia la propagación del campo electromagnético en el interior del metal atravesando las distintas capas de sujeción (duro-níquel) y de protección (inconel), la base se esta compuesta de un acero AISI 304




Figura nº 5.2 Cadena de conexión de los cuadripolos.

Con las consiguientes simplificaciones de las condiciones de contorno y de límite entre caras el proceso físico de propagación de señal en un medio de parámetros distribuidos se modeliza en un proceso de conexión en cascada de cuadripolos, que a su vez muestran paralelismo con las líneas de transmisión. [25]

Tabla nº 5.1 Características eléctricas y magnéticas de los materiales

subíndice	Material	Capa	ρ	Resistividad	μ_r	(*)
i	Inconel	Protección	ρ_i	1,29 $\mu\Omega$ m	μ_{ri}	1
d	Duranickel	Anclaje	ρ_d	42,40 $\mu\Omega$ m	μ_{rd}	1
b	Base de acero	Aisi 304	ρ_b	12,90 $\mu\Omega$ m	μ_{rb}	1

Mientras las equivalencias que se establecen entre el modelo de cuádrupolos y las capas del metal son:

Tabla nº 5.2 Equivalencia entre el modelo de cuádrupolos y la capa de metal

Parámetro		Parámetro	
Permeabilidad (μ)	H/m	Autoinducción (L)	H/m
Conductividad (σ)	S/m	Perditanancia (G)	S/m

El espesor de las capas h es equivalente a la longitud de la línea de transmisión.

La placa base de acero tiene un espesor de 10 mm. Para las dimensiones electromagnéticas a las frecuencias de trabajo es muy elevada, por tanto el primer cuádrupolo equivalente se considera una línea de longitud infinita, por tanto su impedancia de entrada Z_e y su parámetro de transmisión γ_b

Ecuación nº 5.1

$$Z_{eb} = Z_b = \sqrt{\frac{i\omega\mu_b}{\sigma_b}} \quad \gamma_b = \sqrt{i\omega\mu_b\sigma_b}h_b$$

La primera capa de duro-níquel de un espesor hd de 100, 200 y 300 μ m es el segundo cuádrupolo cuya impedancia de cierre es la anteriormente citada y cuyos parámetros de transmisión son

Ecuación nº 5.2

$$Z_{ed} = Z_d = \sqrt{\frac{i\omega\mu_d}{\sigma_d}} \quad \gamma_d = \sqrt{i\omega\mu_d\sigma_d}h_d$$

Con lo que la impedancia a la entrada de esta capa intermedia de longitud hd se obtendrá como:

Ecuación nº 5.3

$$Z_{ed} = Z_d \frac{\frac{Z_b}{Z_d} + \tanh(\gamma_d h_d)}{1 + \frac{Z_b}{Z_d} \tanh(\gamma_d h_d)}$$

Finalmente la capa exterior de protección de inconel tendrá una impedancia de entrada que será la que incide sobre la bobina sensora en el proceso de medida.

Ecuación nº 5.4

$$Z_i = \sqrt{\frac{i\omega\mu_i}{\sigma_i}} \quad \gamma_i = \sqrt{i\omega\mu_i\sigma_i}$$

Así que la impedancia de entrada a la superficie de protección, a su vez, será:

Ecuación nº 5.5

$$Z_{ei} = Z_i \frac{\frac{Z_{ed}}{Z_i} + \tanh \gamma_i h_i}{1 + \frac{Z_{ed}}{Z_i} \tanh \gamma_i h_i}$$

En el caso de existir mas capas de protección se reitera el algoritmo atendiendo a la modificación adecuada de los subíndices.


El modelo pues, sustituye cada distinta capa por un elemento cuadripolar que queda conectado en cascada con las sucesivas capas.

Siguiendo el calculo teórico para la chapa base de acero con dos capas superficiales de distinto espesor, se han trazado las curvas de Resistencia (R), Reactancia (X) para distintos espesores

Curva 1 : espesor capa duro-níquel 100µm


Curva 2 : espesor capa duro-níquel 200µm

Curva 3 : espesor capa duro-níquel 300µm




Gráfica nº 5.1 Medidas de resistencia vs reactancia para distintos espesores de capas.

Las curvas representan la variación de lectura para espesores de la capa de protección de 100, 200, 300, 400, 500 y 600 μm . Para un mismo espesor de capa de anclaje. La distribución de espesores de ambas capas queda circunscrita a los valores extremos que sirven como patrón de medida. En teoría, un sobre-espesor de la capa de anclaje 400 μm nos ofrece la Gráfica nº 5.2, en la que se observa que la curva 4 correspondientes a placas con sobre-espesor queda toda fuera del entorno de confianza y ofrece resultado negativo:



Gráfica nº 5.2 Medidas de resistencia vs reactancia para distintos espesores de capas.

En el caso de insuficiencia de espesor en la capa de anclaje de por ejemplo 50 μm , el resultado teórico es el de la Gráfica nº 5.3.



Gráfica nº 5.3 Medidas de resistencia vs reactancia para distintos espesores de capas.

De nuevo la curva correspondiente al infra-espesor está fuera de límites.

El anterior cálculo, muestra la posibilidad de establecer un método de control y de aceptación en la verificación de las capas de protección y sus correspondientes espesores.

Para la consecución de este objetivo, se hace necesaria la confección de probetas patrón con el siguiente dimensionado:

Probeta de mínimos: 100 μm de h_d y 100 μm de h_i espesores de capa de anclaje (d) y de protección (i) por ejemplo.

Probeta patrón normal: 200 μm de h_d y 400 μm de h_i espesores de capa de anclaje (d) y de protección (i) por ejemplo.

Probeta de máximos: 300 μm de h_d y 600 μm de h_i espesores de capa de anclaje (d) y de protección (i) por ejemplo.

Con las probetas citadas anteriormente se puede calibrar el impedancímetro, estableciendo los límites de aceptación.

Las gráficas anteriores han sido obtenidas para una frecuencia $f = 36 \text{ kHz}$, para conocer como varía teóricamente los valores de R y X para distintas frecuencias, se ha modificado el cálculo de la impedancia de entrada a las frecuencias de 0,001; 0,01; 0,1; 1; 10; 100; 1000 y de 10000 kHz.

Se observa que en el escalonado de frecuencias ($\times 10$), el valor de la reactancia (X) y de la resistencia (R) quedan multiplicados por un factor ($\times 3$) constante en todo el margen de cálculo que va de 1Hz a 10MHz.

La distribución de las curvas se deforma ostensiblemente a partir de las 100 kHz por lo que obliga a pensar que medidas a frecuencias superiores, puede que no ofrezcan una buena información.

Las simplificaciones que se aplican en el método seguido son:

-Las interfaces o intercaras entre las distintas capas son ideales (campos perpendiculares nulos) y campos transversales sin pérdidas. En la práctica, la no planitud de las superficies y la rugosidad observada, darán como resultado una impedancia de contacto que presumiblemente sea constante y no dependa de la frecuencia.

-Se ha supuesto que el material es completamente uniforme en cuanto a los valores de los parámetros distribuidos fundamentalmente la conductividad eléctrica (σ) y la permeabilidad magnética (μ).

-La conductividad eléctrica, se ha supuesto de igual valor a la del material de aportación, lo que presupone que el proceso de formación de las capas, en el que se modifica ostensiblemente la temperatura y presión del material, no influye en el material depositado, lo que obviamente no es cierto.

-La permeabilidad magnética relativa de la capa de duro-níquel, puede que varíe con los cambios de temperatura citados del proceso de deposición, (se supera la temperatura de Curie) y hagan oscilar el valor de μ_r de 4 a 10 con una fuerte dependencia con la frecuencia. La introducción de un valor promedio constante (calculado a partir de la energía magnética equivalente) corregirá a mejor los resultados.

El modelo finalmente supone que la impedancia medida en el equipo es el resultado de añadir al valor de la impedancia de la bobina sobre la capa base la variación que representa la influencia de las capas de aportación consideradas


Ecuación nº 5.6

$$Z_l = Z_b + \Delta Z$$


Z_l Impedancia medida sobre la placa de ensayo.

Z_b Impedancia medida sobre la placa sin protección.


ΔZ Alteración en el valor de la impedancia que aportan las capas de protección.




Gráfica nº 5.4 Medidas de resistencia vs reactancia para distintos espesores de capas a la frecuencia de 0,001 kHz




Gráfica nº 5.5 Medidas de resistencia vs reactancia para distintos espesores de capas a la frecuencia de 0,01 kHz.




Gráfica nº 5.6 Medidas de resistencia vs reactancia para distintos espesores de capas a la frecuencia de 0,1 kHz.




Gráfica nº 5.7 Medidas de resistencia vs reactancia para distintos espesores de capas a la frecuencia de 1 kHz.




Gráfica nº 5.8 Medidas de resistencia vs reactancia para distintos espesores de capas a la frecuencia de 10 kHz.



Gráfica nº 5.9 Medidas de resistencia vs reactancia para distintos espesores de capas a la frecuencia de 100 kHz



Gráfica nº 5.10 Medidas de resistencia vs reactancia para distintos espesores de capas a la frecuencia de 100 kHz.



Gráfica nº 5.11 Medidas de resistencia vs reactancia para distintos espesores de capas a la frecuencia de 1000 kHz.

5.2 Resultados del modelo teórico

Cálculo de los parámetros Z y Y.

Para el cálculo de los parámetros de cada red cuadripolar, se empleó la hoja de cálculo MathCad aplicando la fórmula correspondiente a cada capa. Al tiempo se calcula la "profundidad de penetración" (δ), de acuerdo a la fórmula siguiente, con lo que se obtiene información para comparar dicho valor con los correspondientes espesores de capa. Por esta razón se toma, como más adecuada, la frecuencia de 36kHz como de inspección, y todos los cálculos se realizan a partir de ella.

Ecuación nº 5.7

$$\delta = \sqrt{\frac{2}{\omega\mu\sigma}}$$

5.2.1 Representación gráfica

Con el doble objetivo de determinar la frecuencia de inspección adecuada y establecer un método para controlar los distintos espesores, se toman en consideración los siguientes espesores de placa:


Tabla nº 5.3 Espesores de las placas

h_i (μm)	h_d (μm)
250	50
300	100
400	200
500	300
550	350


Como valores nominales, se toman $h_d = 200 \mu\text{m}$ y $h_i = 400 \mu\text{m}$ con un margen superior/inferior $\pm 100 \mu\text{m}$ y un límite superior/inferior de $\pm 150 \mu\text{m}$. Con estos valores se calculan de forma iterativa las distintas curvas $Z_e = \psi(h_i, h_d)$ tomando h_d fija y h_i variable (trazas horizontales inclinadas) y a su vez h_i fija y h_d variable (trazas verticales inclinadas) con lo que queda determinada el área de control del dimensionado de las capas. Aquellas capa dimensionadas tal que $350 \mu\text{m} > h_i < 50 \mu\text{m}$ o que $550 \mu\text{m} > h_d < 250 \mu\text{m}$ sus traza quedarán fuera del área de control, en la Gráfica nº 5.12 representa la superficie de control mientras en la Gráfica nº 5.13 se refleja la situación para el caso de el espesor h_i fuera de $600\mu\text{m}$.

La impedancia de entrada del modelo en general es un valor complejo, cuya parte real $Re(Z_e)=R$ se representa en el eje x, mientras que la parte imaginaria $Im(Z_e)=X$ emplea

el eje y. Ello se justifica porque es la forma usual en la que los equipos de medir impedancia, pueden ofrecer sus resultados en pantalla.



Gráfica nº 5.12 Contorno para los límites de control.



Gráfica nº 5.13 Ejemplo de placa fuera de límites.

6 Medidas

6.1 Medidas ópticas (probetas X)

El objetivo fijado, es el de medir los espesores de las capas de protección en las probetas confeccionadas al efecto y que se identifican como X. Han sido confeccionadas en tres conjuntos las numeradas del 1 al 12 con el espesor de 560 μm . Las de 13 a 24 con 587 μm y por último la numerada 25 de 650 μm .

De las probetas de 200x200x10 mm, se obtiene una muestra de 10x10 mm de cada una, tomando como referencia para su extracción el centro geométrico de las placas

6.2 Plan establecido.-

De acuerdo al plan establecido, se han cumplimentado las siguientes actividades:

- 1 Recepción de las placas
- 2 Marcación
- 3 Medición de Impedancias (R_s - X_s) mediante sensor de corrientes inducidas
- 4 Corte de las placas en muestras de 10x10 mm.
- 5 Embutición
- 6 Desbaste
- 7 Pulido
- 8 Ataque químico
- 9 Microscopía
- 10 Confección hojas de cálculo
- 11 Medición de espesores
- 12 Análisis de datos
- 13 Estadísticas
- 14 Informe resultado
- 15 Conclusiones

6.3 Equipos

Se han realizado las fotografías, tomadas del perfil transversal de la muestra en un ancho de campo de unos 1200 μm relación de aumentos 1x50 empleando conjunto microscopio cámara Olympus C-50. El tratamiento de las imágenes mediante el soporte informático del equipo Scandium. La segunda medida se ha realizado con un microscopio Nikon Microphot-FX, cámara Sony Exwave HAD, soporte informático Visilog V4 y medidas Corel Paint Shop Pro X3

En ambos casos la medida no es directa a partir de la imagen sino mediante comparación con una medida patrón de 1.000 μm

Se confeccionan ficheros de datos en Hoja Excel de los datos observados.

Para las medidas electromagnéticas se usa el impedancímetro de Hewlett-Packard que consta de los siguiente componentes :

- Agilent 4294 A Precision Impedance Analyzer
- Puente conexión sensor cable Kelvin 16089 B
- Sonda de ferrita 12mm diámetro
- Programa de medidas 4294 A_data_transfer_300

El programa informático proporciona directamente las bases de datos en Hojas Excel para su almacenamiento.

En las medidas electromagnéticas se han tomado lecturas de los dos parámetros considerados más influyentes, la resistencia (R) en Ω y la reactancia, esta última a partir de la medida de la autoinducción del sensor (Ls) en μH .

Como reactivo de ataque metalográfico se emplea Nital, compuesto de agua destilada y ácido nítrico.


6.3.1 Resultados de la medidas ópticas

Los valores significativos en el primer conjunto de medidas son

- Valor medio 586.337 μm
- Desviación típica 94.765 μm

Se han tomado 3 medidas por punto elegido (zona central y dos laterales $\pm 50 \mu\text{m}$) y tres puntos por probeta (zona central y laterales $\pm 4\text{mm}$) aproximadamente. Un total de 216 medidas para 24 probetas.

El Gráfica nº 6.1 muestra es la distribución de las desviaciones respecto al valor medio obtenido. Se constata una notable dispersión de valores mas allá de los $\pm 100 \mu\text{m}$.



Gráfica nº 6.1 Distribución de medidas.





Foto Olympus



Foto Nikon



Patrón de lectura 100 µm

Figura nº 6.1 Fotos de perfiles y del patrón de medida.





Figura nº 6.2 Conjunto de probetas X


Hay que considerar, que en el cálculo anterior se han tomado todas las medidas individuales, si calculamos el espesor medio en cada muestra y analizamos los resultados la media resulta la misma, pero la desviación estándar (entre medias de cada muestra) se reduce a $77.243\mu\text{m}$.

Se ofrece en la Gráfica nº 6.2 la distribución de la estadística en intervalos de $25\mu\text{m}$ y su representación comparada a una distribución normal de iguales parámetros de media y desviación estándar.



Gráfica nº 6.2 Distribución estadística de medidas

Se observa, como era de esperar, una distribución de frecuencias en la medida, sensiblemente similar a una distribución normal.




Gráfica nº 6.3 Contraste con la distribución normal

Comparada a una distribución normal teórica el único punto significativo es el marcado con asterisco en la tabla, en que aparecen tres lecturas discordantes, ver la Gráfica nº 6.3.

Tabla nº 6.1 Tablas de estadística de valores

N	N acum	H	probabilidad	Prob. acum.	diferencias
2	3	387.5	2.52	4.65	-0.21
4	7	412.5	4.24	8.89	-0.06
7	14	437.5	6.64	15.53	0.05
10	24	462.5	9.71	25.24	0.03
19	43	487.5	13.24	38.48	0.44
20	63	512.5	16.83	55.31	0.19
15	78	537.5	19.97	75.27	-0.25
24	102	562.5	22.09	97.36	0.09
18	120	587.5	22.80	120.16	-0.21
20	140	612.5	21.95	142.11	-0.09
25	165	637.5	19.71	161.82	0.27
17	182	662.5	16.51	178.33	0.03
15	197	687.5	12.90	191.23	0.16
2	199	712.5	9.40	200.63	-0.79
5	204	737.5	6.39	207.02	-0.22
4	208	762.5	4.05	211.07	-0.01
4	212	787.5	2.40	213.46	0.67
1	213	812.5	1.32	214.79	-0.24
0	213	837.5	0.68	215.47	-1.00
3	216	862.5	0.33	215.79	8.19
0	216	887.5	0.15	215.94	-1.00
0	216	912.5	0.06	216.00	-1.00

Por otro lado se ha comparado la distribución acumulada con la normal



Gráfica nº 6.4 Comparación distribución normal acumulada

Resultado obtenido en la hoja de cálculo de Statgraphics, para contrastar la "normalidad" del resultado de las medidas de espesores sobre la totalidad de las muestras.

Kolmogorov-Smirnov Test


Estimated overall statistic DN = 0,125

Two-sided large sample K-S statistic = 0,433013

Approximate P-value = 0,991964


The StatAdvisor

This option runs a Kolmogorov-Smirnov test to compare the distributions of the two samples. This test is performed by computing the maximum distance between the cumulative distributions of the two samples. In this case, the maximum distance is 0,125, which you can see visually by selecting Quantile Plot from the list of Graphical Options. Of particular interest is the approximate P-value for the test. Since the P-value is greater than or equal to 0,05, there is not a statistically significant difference between the two distributions at the 95,0% confidence level.




Gráfica nº 6.5 Trazado cuantil – cuantil

Para mayor contraste, se separan las medidas en dos lotes, el primero con los resultados de las placas numeradas 1 a 12 Gráfica nº 6.6 y el segundo con las numeradas de 13 a 24 Gráfica nº 6.7, las gráficas muestran, lo que a nuestro entender es una desviación de sesgo, pues la curva muestra en ambas distribuciones un mínimo relativo en la proximidad del valor máximo.




Gráfica nº 6.6 Divergencia con la distribución normal.



Gràfica nº 6.7 Divergencia con la distribución normal.

Debido a la amplia dispersión, casi 100μm y como medida de contraste, se repiten las medidas para todas las muestras, tomando imágenes con el microscopio Nikon, se obtienen imágenes en archivos JPG y se miden los espesores mediante el programa Corel PaintShop Photo Pro X3, los resultados se comparan y se concluye que apenas hay diferencias ostensibles entre ambas pruebas, lo que valida los resultados obtenidos. Se han realizado y procesado un total de 292 fotografías.



Gràfica nº 6.8 Contraste entre métodos de medidas ópticos.

Tabla nº 6.2 Valore medidos y comparados entre ambos métodos,

sca	diferencia	corel
639,516	46,732	686,247
616,557	23,342	639,90
738,854	2,905	741,759
535,417	6,184	541,601
525,932	-48,282	477,650
651,507	10,610	662,118
592,893	-35,008	557,885
488,551	14,745	503,296
460,722	-5,224	455,498
591,989	-91,923	500,066
542,669	-43,796	498,873
504,406	-13,421	490,985
643,858	-25,648	618,211
639,257	-44,937	594,320
526,562	-31,302	495,260
797,217	-21,382	775,835
648,566	-16,282	632,284
608,283	4,771	613,054
536,818	-43,423	493,395
559,166	0,080	559,246
555,102	35,419	590,521
556,011	-42,996	513,015
568,006	-18,472	549,534
544,242	-14,910	529,332






Tabla nº 6.3

6.3.2 Resultados de las medidas electromagnéticas

Se han realizado pruebas electromagnéticas para su contraste con las medidas ópticas. En una fase se toma una lectura de impedancia en cada una de las muestras. Esta medida, claro está, es previa al corte de las probetas y se toma en el punto de extracción. Posteriormente se repite idénticamente el ensayo en cuatro puntos equidistantes por cada una de las placa (puntos medios de las semidiagonales).



Gráfica nº 6.9 Distribución normal medidas eléctrica.




Gráfica nº 6.10 Medidas de L_s en probetas y placas.

Se observa, al igual que con las medidas ópticas, que existe un punto de sesgo en la zona central de la distribución de las mediciones, lo que indicaría que es el resultado del proceso de confección de las muestras.

Por otra parte, se comparan los dos lotes de medidas y se observa en la gráfica nº 10 que resultan coherentes.

La serie 1 Probetas, es el resultado de la medida de Ls en el punto de extracción. La serie 2 Placas, corresponde a la media de los cuatro puntos de medidas en las placas.

Se estudia la correlación entre ambas medidas eléctricas y ópticas y se muestra en la Gráfica nº 6.11.



Gráfica nº 6.11 Correlación lineal ambos métodos.

Aunque la correlación es débil, se visualiza un valor razonable de ajuste para una función lineal que relacione h (µm) con Ls (µH) con lo que un sistema de detección, pasa no pasa, con los límites de 700 µm a 500 µm sería factible.

6.3.3 Conclusiones

El valor medio obtenido resulta correcto para las dimensiones previstas teóricas, donde no se ha considerado la influencia de la capa de anclaje Duranickel. Sin embargo el elevado valor de la desviación estándar, limita la fijación de una cota mínima para el valor del espeso.

7 Método inverso

7.1 Introducción

Se han realizado medidas en la banda 60 kHz-120 kHz y la de 0,6 MHz-1,2 MHz, estas últimas sin validez para su contraste con los espesores medidos. En las primeras a baja frecuencia si que se observa una cierta correlación con los espesores medidos, pero dado el amplio margen de variabilidad de las medidas en las muestras, no se puede establecer un criterio de medida para obtener un control sobre los espesores. Con los resultados obtenidos si se permite un control “grosso modo” para obtener límites máximo mínimo.[26]

7.2 Método de resolución del Problema Inverso

Para su análisis, se han tomado en consideración las medidas realizadas mediante el Impedancímetro HP 4295A sobre 25 placas. La medida se realiza sobre los parámetros R (resistencia óhmica Ω) y autoinducción. Se realizan cuatro medidas por cada placa en el rango de frecuencia de 6 kHz a 18 KHz (20 lecturas intermedias) y se “normaliza” su valor, al descontar de las medidas absolutas obtenidas, la lectura de la impedancia del sensor en vacío. Con esta operación, se corrigen las lecturas y el calibrado se hace innecesario.

Medidas de parte real de $Z = R_s$

Medidas de parte imaginaria de $Z = L_s$

Se calculan las reactancias

Ecuación nº 7.1

$$Z = Re(Z) + jIm(Z) = R_s + jX_s = R_s + j\omega L_s$$

y se “normalizan”

Ecuación nº 7.2


$$\Delta R = R_s - R_o \quad \text{y} \quad \Delta X = X_s - X_o$$

Se construyen las curvas $\Delta R = \Phi(f)$ y la $\Delta X = \Phi(f)$ y se ajusta a una curva parabólica (a pesar de la clara rectitud de la $\Delta R = \Phi(f)$, con lo que se obtiene sendas ecuaciones de segundo grado de las que resueltas se obtiene la frecuencia de corte f_{or} y f_{ox} para cada componente. Sólo la reactancia la tiene en el rango de frecuencia grafiado.


Se realizan los cálculos para las veinticinco placas y se obtienen dos valores para cada una de ellas, ver Anexo Mathcad nº 12.7:

- f_{or} frecuencia de corte para la resistencia ΔR que se sitúa fuera del gráfico a su izquierda.

- f_{ox} frecuencia de corte para la reactancia ΔX que observa entre 10 y 15 kHz




Gráfica nº 7.1 $\Delta R(f)$ Regresión polinomial para la curva de resistencia.



Gráfica nº 7.2 Regresión polinomial para la curva de reactancia.

Se construyen los perfiles de espesores de las placas por separado empleando las frecuencias f_{0r} y f_{0x} y comparando con las medidas ópticas de las capas de las placas se obtiene el siguiente gráfico:



Gráfica nº 7.3 Comparación entre los valores de h de referencia y los calculados por la curva de regresión.

En Gráfica nº 7.3 se observa que la traza roja de $h = \Phi(f_{0x})$ es inversa a la h óptica mientras que la función $h = \Phi(f_{0r})$ lo hace de forma directa, pero ambas muestran una clara relación con la h (curva verse a trazos).

El problema inverso se resuelve por medio de un regresión lineal de dos variables f_{0r} y f_{0x} se busca una función objetivo $h = \Phi(f_{0r}, f_{0x})$ minimizando el error y obteniendo los factores de la función.[27]

Ecuación nº 7.3

$$f(x, y) = \sum_{i=0}^k a_i x^{l_{i,0}} y^{l_{0,i}}$$

Resultando en nuestro caso lineal $k = 1$ de la forma

Ecuación nº 7.4

$$z(x, y) = a_0 + a_1 x + a_2 y$$


Para

$$x = f_{0r} = 1.185,507$$

$$y = f_{0x} = 13.254,514$$

Frecuencias de corte para (por ejemplo) la placa 12 se obtiene una $h_w = 603.591$ para una medida esperada de $h = 645.03$ en su medida óptica.

En la grafica se resumen los resultados para todas las placas.



Gráfica nº 7.4 Resolución del problema inverso.

Las pocas discrepancias con el resultado ideal se deben a la falta de uniformidad de las placas patrón de las que no olvidemos se ha simplificado el hecho de unificar en un sólo espesor lo que en realidad son dos capas.

Se anexan tabla de valores calculados para cada placa de las frecuencias de corte y los resultados comparados con las medidas ópticas, ver Anexo Mathcad nº 12.7.

8 Redes neuronales artificiales

8.1 Antecedentes históricos

ARS MAGNA

En esta obra original de Ramón Llull (alrededor del siglo XIII) se plantea un algoritmo para poder responder automáticamente a todas las preguntas de varias ciencias, incluso a la teología. Es conocido por ser el primer intento de crear una lengua universal media, de algoritmos y combinatoria con gran influencia posterior sobre Leibniz.

Algoritmo (3)

Procedimiento general por medio del cual se puede encontrar la solución o respuesta a cada problema o pregunta de una clase, de modo puramente mecánico y en un número finito de pasos

Estocástico

Pertenece o relativo al azar

Pascalina

Antepasado remoto del actual operador fue la máquina diseñada por Blaise Pascal. Calculadora mecánica (engranajes) que resolvía automáticamente un número determinado de operaciones matemáticas sencillas (sumas y restas).

Máquina de Turing

Calculadora ideal cuya capacidad se supone infinita, que permite definir el concepto de calculabilidad o habilidad de calcular de funciones, basada en la mecanicidad del uso de los algoritmos. Diseñada para resolver el problema publicado por la Sociedad Matemática de Londres [28]. La máquina de Turing es un modelo matemático abstracto que formaliza en concepto de algoritmo.

Perceptrón

En 1958 el psicólogo Frank Rosenblatt [29] desarrolló un modelo simple de neurona artificial basado en el modelo de McCulloch y de Pitts y en una regla de aprendizaje basado en la corrección del error a este modelo le llamó perceptrón. Una de las características que más interés despertó fue su capacidad de aprender a reconocer patrones. Lo que lo hace muy útil para emular funciones.

(3) Sobrenombre del matemático árabe Abu Abdallah Muḥammad ibn Mūsā al-Jwārizmī (Abu Yāffar) **Al Juarismi** entre siglos IX-X

8.1.1 Antecedentes

Si bien fue el genio de Alan Turing el primero en estudiar el cerebro, fueron Warren S. McCulloch neurofisiólogo y Walter Pitts [30] matemático quienes en 1943 lanzaron la primera teoría acerca del funcionamiento de las neuronas. Ellos modelaron una red neuronal simple mediante circuitos eléctricos, el desarrollo posterior ha sido imparable, generalmente se considera el la Conferencia de Dartmouth como el nacimiento de la inteligencia artificial en 1956 [31] un año después Frank Rosenblatt desarrollo el concepto del perceptrón estableciendo el teorema de la convergencia del perceptrón en 1986 David Benja y J Hilton descubrieron el algoritmo de aprendizaje de propagación hacia atrás o retro propagación.[32]

Las Redes Neuronales Artificiales (RNAs) son modelos que utilizan una densa interconexión de elementos sencillos de cálculo, conocidas como neuronas, en combinación con los denominados algoritmos de entrenamiento para hacer que su estructura (y por tanto su respuesta) pueda adaptarse a la información que se les presenta. Las RNAs tienen analogías con redes neuronales biológicas, tales como las de los sistemas nerviosos.

Las RNAs son algunos de los modelos empíricos más sofisticados disponibles y han demostrado ser especialmente buenas en el modelado de sistemas complejos. Su capacidad para extraer relaciones entre entradas y salidas de un proceso, sin que su física esté prevista expresamente para ello, se adapta teóricamente al problema de relacionar las variables electromagnéticas de una sonda de inspección con las características físicas de un medio observado propiedades y dimensiones.

El objetivo de esta investigación es demostrar que los modelos de RNA son capaces de modelar con precisión la relaciones entre las características electromagnéticas de la sonda y las características físicas del medio observado.

El tipo de RNA que se estudia en esta investigación es la llamada feedforward, red multicapa estática. Las RNAs fueron utilizadas como modelos de causa y efecto puros (es decir, el campo electromagnético excitador y la respuesta por medio de las corrientes inducidas).

8.1.2 Introducción

Las redes neuronales artificiales (RNAs) son redes de elementos computacionales simples que son capaces de adaptarse a un entorno de información. Esta adaptación se realiza por ajuste de las conexiones internas de la red a través de la aplicación de un determinado algoritmo. Por lo tanto, las RNA son capaces de descubrir y relacionar de forma aproximada los datos contenidos en la red con los datos que se presentan a su entrada.

as aplicaciones de las RNA son cada vez más populares desde el resurgimiento de estas técnicas en la última parte de la década de 1980. Desde la década de 1990, las RNAs se han utilizado con éxito en el área de los ensayos no destructivos.

La razón por la cual se pretende emplear una RNA para el modelado de la relación entre las componentes real e imaginaria de la impedancia y las dimensiones de las distintas capas de protección es porque la complejidad de su cálculo analítico (problema inverso) la hace irrealizable.

Las RNAs han demostrado ser especialmente buenas en el modelado complejo y en sistemas no lineales. Otros méritos importantes de estas técnicas son el corto tiempo de desarrollo de modelos de RNA, su flexibilidad y el hecho de que no se necesita una gran experiencia en un determinado campo con el fin de ser capaz de aplicar técnicas en este campo.

El objetivo principal de esta investigación es demostrar que las RNA puede resolver el problema inverso[33] con éxito al interpretar los resultados de las mediciones.

Esta investigación sólo se centra en un tipo RNA: el llamado multicapa estática con retroalimentación directa.

8.2 Redes Neuronales Artificiales

El contenido de este capítulo 8 es el resultado de una investigación somera de la literatura existente sobre los principios básicos de las Redes Neuronales Artificiales (RNA) en inglés *Artificial Neural Network (ANN)*.

Después de una breve introducción sobre los orígenes de las RNA en el apartado 8.1.1, su estructura teórica básica se explica en 8.4. En dicha sección se describen los componentes de esta estructura y se explica cómo un red funcional está formada por interconexiones entre estos componentes.

El estudio general que ofrece este capítulo; se centra principalmente en los principios básico de RNA y en las técnicas y tipos de RNAs que son capaces de mapear relaciones.

8.3 Introducción a la tecnología RNA

El primer apartado e esta introducción presentará algunas definiciones y descripciones de las RNA y técnicas para las RNA, dilucidar la "idea general" que hay detrás de ellas. Lo que se explica posteriormente en 8.3.2 es la relación entre la neurociencia y RNA, después de lo cual se revisa el inciso final de la evolución de las técnicas RNA.

8.3.1 ¿Qué es una red neuronal artificial?

Las RNAs son los ejemplos más conocidos de estructuras de procesamiento de información que han sido concebidos en el campo de la neurocomputación. La neurocomputación es la disciplina tecnológica en cuestión con información de los sistemas de procesamiento que de forma autónoma a desarrollar las capacidades operativas en respuesta adaptativa a un entorno de información]. La neurocomputación también se conoce como procesamiento distribuido en paralelo.

En otras palabras, las RNA son modelos que utilizan densa interconexión de elementos computacionales simples en combinación con algoritmos específicos para hacer su estructura (y por lo tanto su respuesta) adaptarse a información que se presenta a ellos. Hecht-Nielsen [34] propone la siguiente definición formal de un RNA (4):

“Definición 1.-Una red neuronal es un paralelo, la estructura de procesamiento de información distribuida que consiste en elementos de proceso (que puede poseer una memoria local y puede llevar a cabo operaciones de procesamiento de información localizada) interconectados a través de canales ramificados de señal unidireccional llamados ramas ('fans out') en la mayor cantidad de conexiones colaterales como se desee; cada una lleva la misma señal, la señal de salida de elemento de procesamiento. Los procesamiento de la señal de salida del elemento puede ser de cualquier tipo matemático deseado. Los procesamiento de la información que va en el interior de cada elemento de procesamiento puede definirse arbitrariamente con la restricción de que debe ser completamente local; es decir, que debe depender sólo en los valores actuales de las señales de entrada que llegan al elemento de procesamiento a través de conexiones incidentes y en los valores almacenados en la memoria local del elemento de procesamiento.”

Desde un punto de vista matemático, las RNAs pueden ser llamadas aproximadores universales, debido a que son relaciones a menudo capaces de descubrir y aproximar en los diferentes tipos de datos. A pesar de que una proceso subyacente puede ser complejo, una RNA puede muy bien a un determinado fenómeno siempre y cuando la cantidad de datos disponibles sea la apropiada.

8.3.2 Las analogías entre los sistemas nervioso y las RNA

Las técnicas de RNA son concebidas con a semejanza del funcionamiento de los sistemas nerviosos de animales y del hombre. Detrás de este intento de imitar está el deseo de reproducir su poder y su flexibilidad de manera artificial. Sin embargo, hay poca semejanza entre la funcionamiento de las RNAs y el funcionamiento del sistema nervioso del cerebro. Esto se debe principalmente a nuestro limitados conocimientos sobre el funcionamiento del sistema nervioso y debido al hecho de que las neuronas artificiales son una simplificación de sus contrapartes del mundo real.

(4) Hecht-Nielsen utiliza el término *red neuronal* en su definición, vamos a utilizar el nombre *Red Neuronal Artificial*. Este último término se emplea hoy en día de manera más amplia, porque de esa manera en una clara distinción *redes neuronales biológicas y artificiales*.

Las redes neuronales biológicas reciben información de los sentidos en diferentes ubicaciones en la red. Esta información viaja de neurona a neurona a través de la red, después de lo cual una se genera respuesta adecuada a la información. Las neuronas biológicas pasan la información de una a la otra mediante la liberación de productos químicos, que causan una sinapsis (un conexión entre las neuronas) generando una corriente eléctrica. La neurona receptora puede o pasar esta información a otras neuronas en la red o bien negar su entrada, lo cual amortigua el impacto de la información. Este es una característica importante de las neuronas biológicas, y su homólogo artificial las cuales replican su comportamiento en cierto modo.

Hay muchas variaciones en el tipo básico de neurona, pero todas las neuronas biológicas tienen los mismos cuatro componentes básicos, como se muestra en la Figura nº 8.1.




Figura nº 8.1 Una neurona biológica.

Dendrita	-Acepta la señal de entrada
Soma	-Procesa las señales de entrada
Axón	-Procesado de conversión entradas en salidas
Sinapsis	-Transmite señales a otras neuronas

Las operaciones de las neuronas biológicas no son todavía entendidas completamente. En consecuencia, sobre una red con gran cantidad de neuronas (como el cerebro) sólo se tiene un conocimiento primitivo sobre su forma más básica de funcionamiento.

Los neurocientíficos siguen desarrollando nuevos conceptos y modelos funcionales del cerebro con el fin de aumentar su comprensión del cerebro, científicos en el campo de la computación neuronal pueden beneficiarse de estas ideas en el desarrollo de nuevas técnicas para las RNAs. Esta situación se produce también a la inversa: el desarrollo de nuevas arquitecturas de RNAs, así como conceptos y teorías sobre el funcionamiento de estas arquitecturas puede conducir a ideas útiles para los neurocientíficos.

La similitud entre el sistema nervioso y las RNA se vuelve más clara cuando se compara la descripción de las neuronas biológicas con la descripción en 8.4. de la estructura de la RNA.

8.3.3 Evolución de las técnicas RNA

La obra de W.S. McCulloch y Pitts W.A. [30] recoge la mayoría de los avances en la computación y la neurociencia a finales del siglo XIX y principios del siglo XX. Su investigación fundamental sobre la teoría de la computación neuronal en la década de 1940 condujo a los primeros modelos neuronales. Muchas teorías sobre Técnicas RNA fueron elaborada en la década siguiente. Los avances que se hicieron, encaminados a la construcción de los primeros ordenadores neuronales. El primer neuroordenador construido con éxito, fue el Mark I Perceptron, que fue construido por Rosenblatt en 1958. Muchas otras implementaciones de neuroordenadores fueron construidas en la década de 1960. Block [35] en 1969 realiza una revisión de la "New Theory" y desarrolla la teoría matemática para los perceptrones de Minsky y Papert .

En 1969, en un análisis teórico por Minsky y Papert [36] se revelaron las limitaciones más significativas de modelos sencillos como el Perceptrón y muchos científicos en el campo de la computación neuronal se desanimaron en proseguir con más investigaciones. Kohonen en 1987 [37] afirma que la falta de problemas computacionales para desarrollar técnicas de resolución a mayor escala, así como los pocos medios proporcionados para la investigación en el campo de la neurocomputación, eran las principales razones de este estancamiento.

A mitad de camino la década de 1980, el interés en las RNAs aumentaron significativamente, gracias a JJ Hopfield, [38] que se convirtió en el protagonista de la revitalización de la computación neuronal. Durante los años siguientes, muchos de las limitaciones se superaron. Las mejoras en las técnicas de RNA existentes en combinación con el aumento de los recursos computacionales condujo a la aplicación exitosa de RNAs para muchos problemas. Uno de los redescubrimientos más innovadores fue el de la técnica de la retro propagación (que fue concebida por Rosenblatt) desarrollada por McClelland y Rumelhart 1986 [39]. Estos desarrollos condujeron a un crecimiento explosivo del entorno de las RNA (5). El número de conferencias, libros, revistas y publicaciones se ha expandido rápidamente desde entonces hasta nuestro días. Las RNAs se utilizan normalmente para el modelado de relaciones complejas en situaciones donde el conocimiento de los sistemas investigados es insuficiente para los modelos convencionales, o bien si el desarrollo de un modelo convencional es demasiado costoso en términos de tiempo y dinero. Las RNAs se han aplicado en varios campos en los que se encontró esta situación. Algunos ejemplos de los campos de trabajo que muestran el amplio posibilidades de RNA son: control de procesos (por ejemplo, la robótica, reconocimiento de voz), la economía (por ejemplo, la moneda la predicción de precios) y los militares (por ejemplo, sonar, radar y procesamiento de señal de imagen).

A pesar de esta amplia gama de aplicaciones, es seguro decir que estos campo están todavía en una etapa relativamente temprana de desarrollo.

⁵ El conexionismo y los modelos PDP (Procesamiento Distribuido en Paralelo) trajeron consigo una profunda reformulación de los procedimientos de la RNAs.

8.4 Bases para las RNAs

En esta sección se discuten las bases teóricas de las RNA, su forma de trabajar, como se complementan entre sí y la forma en que (a mayor escala) forman una RNA funcional.

8.4.1 Descripción Marco general

Según Rumelhart, Hinton y McClelland], [39] hay ocho componentes principales de modelos de procesamiento distribuido paralelo como RNAs:

13. Un conjunto de elementos de procesamiento (neuronas)(6);
14. Un estado de activación;
15. Una función de salida para cada neurona;
16. Un patrón de conectividad entre las neuronas;
17. Una regla de propagación de los patrones de las actividades a través de la red de conectividades;
18. Una regla de activación para la combinación de las entradas que inciden sobre una neurona con el estado actual de esa neurona para producir un nuevo nivel de activación para la neurona;
19. Una regla de aprendizaje mediante el cual los patrones de conectividad son modificados por la experiencia;
20. Un entorno dentro del cual el sistema debe operar.

Algunas de las relaciones entre estos componentes se visualizan en la Figura nº 8.2 . Esta figura representa un esquema de dos neuronas artificiales y las transformaciones que tienen lugar entre la entrada y la salida.

Supongamos un conjunto de elementos de procesamiento (neuronas); en cada punto en el tiempo, cada neurona u_i tiene un valor de activación, denotada en el diagrama como $a_i(t)$; este valor de activación se pasa a través de una función f_i para producir un valor de salida $o_i(t)$. Este valor de salida puede ser visto como pasa a través de un conjunto de conexiones unidireccionales a otras neuronas en el sistema. Lo que está asociado con cada conexión es un número real - usualmente llamado el peso de la conexión, designado w_{ij} - que determina la cantidad de efecto que la primera neurona tiene en la segunda. Todas las entradas deben entonces ser combinados por algún operador (por lo general adición), después de lo cual las entradas combinadas a una neurona, junto con su actual valor de activación, para determinar su nuevo valor de activación a través de una función de F_i . finalmente, los pesos de estos sistemas pueden sufrir modificaciones en función de la experiencia. Esta es la forma en que el sistema puede adaptar su comportamiento, con el objetivo de mejorar su rendimiento.

(6) El término **neurona** se utilizará a partir de ahora cuando se hace referencia a las neuronas artificiales. El uso se justifica por el hecho de que en el contexto de las Redes Neuronales Artificiales una referencia a las neuronas, obviamente, hace a referencia a las neuronas artificiales




Figura nº 8.2 Representación esquemática de dos neuronas artificiales y sus procesos internos [Rumelhart, Hinton y McClelland, [39].

Las características y ejemplos de los componentes antes mencionados de RNAs se presentarán en el siguientes subsecciones con más detalle. La estructura básica de estas secciones también se basa en el trabajo de Rumelhart, Hinton y McClelland [39].

8.4.2 Neuronas y capas

Las neuronas son los elementos computacionales relativamente simples que forman los bloques de construcción básicos de las RNA. Las neuronas también pueden ser referidas como elementos de procesamiento o nodos. Por lo general están dispuestas en capas (ver Figura nº 8.3). Por convención las entradas que reciben los datos se denominan **unidades entrada** (7) y la capa que transmite los datos fuera de la RNA se llama la capa de salida. Las capas internas, donde el procesamiento interno intermedio se lleva a cabo, tradicionalmente se llaman a capas ocultas [Dhar y Stein, [40]. Hay tantas neuronas de entrada y como de salida, ya que hay variables de entrada y de salida respectivamente. Las capas ocultas pueden contener cualquier número de neuronas. No todas las redes tienen capas ocultas.

Las neuronas generalmente se indican con círculos en los diagramas mientras que las conexiones entre las neuronas se representan por líneas o flechas. La neuronas de entrada se representan como cuadrados o círculos pequeños para hacer una diferenciación clara entre las neuronas ocultas o de salida.

(7) En algunas obras las unidades de entrada se denominan neuronas de entrada dentro de una capa de entrada. Dado que estas unidades no sirven a ningún propósito, salvo pero para pasar información a la red (sin la transformación de los datos realizados por neuronas regulares), las etiquetamos unidades de entrada y no tendremos en cuenta el conjunto de estas unidades como una capa de red




Figura nº 8.3 Un ejemplo de una RNA de tres capas, mostrando neuronas dispuestas en capas.

8.4.3 Estado de activación

El estado del sistema en un cierto punto en el tiempo está representado por el estado de activación de las neuronas de una red. Si sea n el número de neuronas, el estado de un sistema puede ser representado por un vector de N números reales, $\mathbf{a}(t)$, que especifica el estado de activación de las neuronas en una red. Según el modelo de RNA, los valores de activación pueden ser de cualquier tipo matemático (entero, real número, número complejo, Booleano, etc.) Los tipos de activación continua pueden estar delimitado dentro de un cierto intervalo.

8.4.4 Salida de las neuronas

Las neuronas interactúan mediante la transmisión de señales a sus vecinas. La fuerza de sus señales es determinada por su grado de activación. Cada neurona tiene una función de salida que determina el estado de activación de una señal de salida:

Ecuación nº 8.1

$$o_i(t) = f(a_i(t))$$

Esta función de salida es a menudo la función identidad $f(\mathbf{x}) = \mathbf{x}$ (de modo que el valor de activación actual se transmite a otras neuronas), o algún tipo de función de umbral (de modo que una neurona no tiene efecto en otras neuronas a menos que su activación sea superior a un cierto valor).

El conjunto de valores de salida está representado por un vector $\mathbf{o}(t)$. La función de salida está relacionada con lo que se denomina el sesgo de una neurona. Una situación en la que función de salida es igual a la función identidad se conoce como una situación en la que "no hay sesgo para la neurona que se utiliza". Un sesgo de 0,5 básicamente significa que una función umbral se utiliza para la función de salida y que la señal sólo pasa a través de la neurona si su valor de entrada excede 0,5.

8.4.5 Patrón de conectividad

Las neuronas están conectadas entre sí. Básicamente, este es el patrón de conectividad que determina cómo una red responderá a una entrada arbitraria.

Las conexiones entre las neuronas varían en intensidad. En muchos casos se supone que las aportaciones de todas las neuronas entrantes son simplemente multiplicadas por un peso y se suman para obtener la entrada general a esa neurona. En este caso el patrón total de conectividad se puede expresar mediante la especificación de cada uno de los pesos en el sistema. No es necesario que una neurona pueda estar conectada a todas las neuronas de la siguiente capa. Por lo tanto, se pueden producir valores nulos para estos pesos.

A menudo es conveniente utilizar una matriz W para expresar todos los pesos en el sistema, como la figura muestra a continuación.




Figura nº 8.4 Ejemplo de pesos de la red y la matriz de pesos que la acompaña [Hecht-Nielsen,[41].

$$W = \begin{bmatrix} w_{11} & \dots & \dots \\ \dots & \dots & \dots \\ \dots & \dots & w_{Nn} \end{bmatrix}$$

El peso w_{21} , por ejemplo, es el peso por el cual la salida del primer nodo una capa se multiplica con cuando está transmitida al segundo nodo de la capa siguiente.

A veces se requiere un patrón más complejo de la conectividad. Una neurona determinada puede recibir entradas de diferentes tipos cuyos efectos se suman por separado. En tales casos, es conveniente tener matrices de conectividad separados para cada tipo de conexión. Las conexiones entre las neuronas a menudo se clasifican por su dirección en la arquitectura de red:

21. Conexiones Feedforward son conexiones entre neuronas en capas consecutivas. Se dirigen de la entrada a la salida.
22. Conexiones laterales son conexiones entre las neuronas de la misma capa
23. Conexiones recurrentes son las conexiones a una neurona de una capa anterior. Están dirigidas de la salida a la entrada.

8.4.6 Regla de propagación

La regla de propagación de una red describe la forma en que se calcula la llamada (**net input**) entrada neta de una neurona a partir de varias salidas de las neuronas vecinas. Típicamente, esta entrada neta es la suma ponderada de la entradas a la neurona, es decir, la salida de los nodos anteriores multiplicada por la matriz de pesos:

Ecuación nº 8.2

$$net(t) = W \cdot o(t)$$

8.4.7 Regla de activación

La regla de activación, - a menudo llamada función de transferencia - determina el nuevo valor de activación de una neurona basada en la entrada neta (y a veces el valor previo de activación, en el caso de que se utilice una memoria). La función **F**, la cual toma **a(t)** y los vectores **net** para cada tipo diferente de conexión, produce un nuevo estado de activación.

F puede variar de una función identidad simple, de modo que $a(t+1) = net(t) = W \cdot o(t)$, a funciones de variación lineal e incluso funciones no lineales como las funciones sigmoideas. Las funciones de transferencia más comunes se enumeran a continuación:

La función de activación lineal:

Ecuación nº 8.3

$$a(t + 1) = F_{lin}(net(t)) = \alpha \cdot net(t) a(t + 1)$$

24. función de activación del limitador duro:

Ecuación nº 8.4

$$a(t + 1) = F_{hl}(net(t)) = \begin{cases} \alpha & \text{if } net(t) < z \\ \beta & \text{if } net(t) \geq z \end{cases}$$

25. función de activación lineal de saturación :

Ecuación nº 8.5

$$a(t + 1) = F_{sls}(net(t)) = \begin{cases} \alpha & \text{if } net(t) < z \\ net(t) + \gamma & \text{if } z \leq net(t) \leq y \\ \beta & \text{if } net(t) > y \end{cases}$$

26. función de activación de Gauss:

Ecuación nº 8.6

$$a(t + 1) = F_{ag}(net(t)) = e^{-\frac{(net(t))^2}{\alpha}}$$

donde α es un parámetro que define la amplitud de la curva de Gauss, como se ilustra la **Error! Reference source not found.**

27. función de activación sigmoidea binaria :

Ecuación nº 8.7

$$a(t + 1) = F_{bs}(net(t)) = \frac{1}{1 + e^{-\alpha net(t)}}$$

donde α es el parámetro de pendiente de la función. Por diferentes este parámetro, diferentes formas de la función se puede obtener, como se ilustra en Figura 8-9.

28. función de activación sigmoidea tangente hiperbólica:

Ecuación nº 8.8

$$a(t + 1) = F_{sth}(net(t)) = \tanh(net(t))$$




Figura nº 8.5 Función lineal




Figura nº 8.6 Función escalón




Figura nº 8.7 Función rampa




Figura nº 8.8 Función de Gauss




Figura nº 8.9 Función sigmoide binaria




Figura nº 8.10 Función sigmoide tangente hiperbólica

8.4.8 Aprendizaje

Sobre la base de datos del ejemplo Anexo 12.4.1 que se presenta a la misma durante una etapa de *entrenamiento*, una RNA intentará aprender las relaciones que están contenidas dentro de los datos de la muestra mediante el ajuste de sus parámetros internos (es decir, los pesos de las conexiones en la red y los sesgos de la neurona). Esto significa que las relaciones que es necesario aproximar están parametrizadas en la estructura de la RNA.

La forma en que una red se entrena es una propiedad básica de una RNA. Varias propiedades de las neuronas y la forma en que se estructuran están estrechamente relacionadas con el algoritmo elegidos. El algoritmo que se utiliza para optimizar los pesos y sesgos se denomina algoritmo de entrenamiento o algoritmo de aprendizaje.

Los algoritmos de entrenamiento se pueden clasificar, a grandes rasgos, en los que comprenden el aprendizaje supervisado y el aprendizaje no supervisado.

El aprendizaje supervisado funciona mediante la presentación de la RNA con datos de entrada y los resultados de salida correctos. Esto se hace mediante un "maestro" externo, de ahí el nombre de este método.

La red genera una estimación, basada en la entrada dada, y luego compara su de salida con los resultados deseados. Esta información se utiliza para ayudar a guiar la RNA en su entrenamiento. Algunos métodos de aprendizaje no presentan el valor real deseado de la salida a la red, sino más bien dan una indicación de la exactitud de la estimación.

Un sencillo algoritmo de ejemplo es el que sigue:

Ecuación nº 8.9

$$w(j)^t = w(j) + \alpha \cdot (\delta - y) \cdot x(t)$$

en la que $w(j)$ peso ; α tasa de aprendizaje en general $0 < \alpha < 1$; δ salida prevista; y salida.

En el que se observa como el peso se reajusta en cada iteración hasta alcanzar el equilibrio después de n iteraciones , esto no es siempre posible y el periodo de aprendizaje no se alcanza.

Estos métodos de aprendizaje tienen una clara relación con el proceso de calibración, que se usa en muchas técnicas de modelado convencionales. Esto se hace evidente al comparar la anterior con Rientjes y Boekelman [2001], por ejemplo, el estado: es necesario un procedimiento de ajuste de los valores de los parámetros del modelo para que coincida con los resultados salida de los datos medidos para el período seleccionado y la situación de entrada al modelo. Este proceso de (re) ajuste y (re) calculado es la calibración y la búsqueda del conjunto óptimo de parámetros del modelo".

Las RNAs que son entrenadas utilizando un paradigma de aprendizaje no supervisado únicamente se presentan con los datos de entrada, pero no con los resultados deseados. La red no es supervisada con respecto a lo que se 'supone' debe de encontrar y le corresponde a la red el descubrir posibles relaciones de los datos de entrada y en base a esto que ciertas predicciones de una salida. [Dhar y Stein, [40]

Tabla nº 8.1 Resumen de las técnicas de aprendizaje supervisado

Aprendizaje supervisado	
Rendimiento de aprendizaje	Coincidencia de aprendizaje
29. Retro propagación 30. Métodos basados en algoritmos de optimización estadística o Los algoritmos de gradiente conjugado o (Quasi-) Algoritmo de Newton o (Reducido) Algoritmo de Levenberg-Marquardt 32. Algoritmo de Correlación en cascada	31. Aprendizaje Hebbiano (Hebb)

Tabla nº 8.2 Resumen de las técnicas de aprendizaje no supervisado

Aprendizaje no supervisado	
Aprendizaje competitivo	Aprendizaje filtrado
33. Aprendizaje Kohonen Teoría de Resonancia Adaptativa (ART)	34. Aprendizaje Grossberg

El aprendizaje supervisado y no supervisado puede ser dividido en diferentes clases, como se muestra en la Tabla 2.1 y la Tabla 2.2.

El comportamiento de los algoritmos de aprendizaje se discutirá en la siguiente sección, ya que éstos son los algoritmos utilizados en esta investigación.

Rendimiento de los algoritmos de aprendizaje

Una RNA que está entrenada usando un método de aprendizaje supervisado intenta encontrar parámetros internos óptimos (pesos y sesgos) mediante la comparación de sus propias aproximaciones de un proceso con los valores reales de ese proceso y posteriormente ajustar sus pesos (y sesgos (8)) para hacer su aproximación más próxima al valor real. La comparación antes mencionada se basa en una evaluación usando una función de rendimiento (de ahí el nombre de aprendizaje competitivo). Esta función es la llamada como función error (9).

(8) El uso de sesgos no es muy común. La formación de una RNA a menudo sólo se reduce a la actualización de la red pesos. A partir de este punto, no se hará caso de los sesgos en la discusión sobre el proceso de formación.

(9) La función de rendimiento nombre es un poco engañoso, ya que básicamente es una función que expresa el valor de los errores residuales de la RNA. Dado que la función es minimizada durante el entrenamiento de la RNA el nombre función error es preferible.

Supongamos que una red está tratando de aproximar un determinado proceso, que puede ser caracterizada por un número de n variables (ver Figura nº 8.11). La entrada de la red es un vector \mathbf{x} y los pesos de la red forman una matriz W . La aproximación de la red es un vector de n variables llamada $\mathbf{y} = (y_1, y_2, \dots, y_n)$ (que es una función de \mathbf{x} y W) y los valores reales de las variables están incluidos en un vector llamado $\mathbf{t} = (t_1, t_2, \dots, t_n)$. La diferencia entre los dos se utiliza para calcular un error de aproximación E . Para que una RNA genere un vector de salida \mathbf{y} que sea lo más cercano posible al vector \mathbf{t} , se emplea un algoritmo para encontrar los parámetros internos óptimos que minimizan una función de error. Esta función por lo general tiene la forma:

Ecuación nº 8.10

$$E = \sum_{h=1}^n (t_h - y_h)^2$$

donde n es el número de neuronas de salida.




Figura nº 8.11 Ejemplo de una red de alimentación directa de dos capas.

La Ecuación nº 8.10 se basa en la expresión del error cuadrático medio (ECM). Este sistema de medición del error se utiliza a menudo, ya que tiene ciertas ventajas. En primer lugar, asegura que los grandes errores reciben mucha más atención que los pequeños errores, que es por lo general lo que se desea. En segundo lugar, tiene en cuenta la frecuencia de ocurrencia de las entradas. El es la mejor opción si los errores se distribuyen normalmente cerca. Otras medidas como el error residual pueden ser más apropiadas si, por ejemplo, la evaluación de los errores no se distribuyen normalmente o cuando se examinan aspectos específicos de un proceso que requiere de una medida de error diferente. Ejemplos de medidas de error alternativas son la media error absoluto y variantes del ECM, como la Raíz del Error Cuadrático Medio (RECM).

Dado que y es una función de los pesos \mathbf{W} en la función de error (\mathbf{E}), esta se convierte en una función de \mathbf{W} de la red que está siendo evaluada. Para cada combinación de pesos surge un error residual diferente.

Estos errores pueden ser visualizados por el trazado de ellos en una dimensión extra además de las dimensiones del espacio de pesos de la red. Por ejemplo: asumir una red con dos pesos, w_1 y w_2 . El espacio de peso de dos dimensiones se puede ampliar con una tercera dimensión en la que el error residual \mathbf{E} para cada combinación de los pesos w se expresa como w_1 y w_2 . El resultado se puede trazar como una superficie tridimensional (como se hace en la Figura nº 8.12. Los puntos en esta superficie de error son especificados por tres Coordenadas: el valor de w_1 , el valor de w_2 y el valor del error \mathbf{E} para esta combinación de $w_1 w_2$.

La meta para los algoritmos de aprendizaje es encontrar el punto más bajo en esta superficie, es decir, el peso donde el vector de error residual es mínimo. Podemos visualizar el efecto de un buen algoritmo como una pelota rodando hacia un mínimo en la superficie (ver Figura nº 8.12).

Hay que considerar que la forma de la superficie de error depende de la función de error utilizada.




Figura nº 8.12 Ejemplo de una superficie de error anterior a un espacio de peso de dos dimensiones.

El punto de partida, desde el cual un algoritmo de entrenamiento trata de encontrar un mínimo, se determina por valores iniciales de los pesos de la red en el inicio de la formación. Estos pesos se establecen a menudo a valores aleatorios pequeños.

Los algoritmos de aprendizaje de rendimiento pueden actualizar los pesos de la RNA justo después de procesar cada muestra de entrenamiento. Otra posibilidad es la

actualización de los pesos de la red sólo después de procesar todo el conjunto de datos. Esta actualización se forma comúnmente como un promedio de las correcciones para cada muestra individual de entrenamiento. Este método se llama la formación de lote o lotes actualización. Trabajos anteriores han demostrado que este método es más adecuado si se utiliza un algoritmo más sofisticado.

Si se utiliza el aprendizaje por lotes, la función de error que tiene que ser minimizado tiene la forma:

Ecuación nº 8.11

$$E = \sum_{h=1}^p \sum_{q=1}^n (t_{qh} - y_{qh})^2$$

donde n es el número de neuronas de salida y p el número de patrones de entrenamiento.

La actualización por lotes introduce un efecto de filtrado a la formación de una RNA, que en algunos casos puede ser beneficioso. Este enfoque, sin embargo, requiere más memoria y añade una complejidad computacional extra.

En general, la realización de un algoritmo de actualización por lotes es muy dependiente de caso. Un buen compromiso entre la actualización paso a paso y la actualización por lotes es acumular los cambios a lo largo, pero no todos los pares de formación antes de que los pesos se actualicen.

Todos los algoritmos de aprendizaje tratan de encontrar el conjunto óptimo de parámetros de la red interna, es decir, el mínimo global de la función de error. Sin embargo, puede haber más de un mínimo global de esta función, por lo que existe más de un conjunto de parámetros que se aproximan a los datos de entrenamiento de manera óptima. Además del mínimo global, las funciones de error a menudo cuentan con múltiple mínimos locales. Es importante darse cuenta que es muy difícil saber con certeza si una red entrenada ha llegado a un mínimo local o a un mínimo global.

Retro propagación Estándar

El algoritmo más conocido para la formación RNAs es el algoritmo de retro propagación. En esencia, busca para los mínimos en la superficie de error mediante la aplicación de una técnica de gradiente de descenso más pronunciado. El algoritmo es linealmente convergente. La arquitectura de la retro propagación descrito aquí y en el Anexo 12.4.2 es la versión básica, clásica, pero existen muchas variantes de esta forma básica. Básicamente, cada patrón de entrada del conjunto de datos de entrenamiento se hace pasar a través de una red de alimentación directa desde las unidades de entrada a la capa de salida. La salida de la red se compara con los valores de salida deseados, y se calcula el error basándose en una función de error. Este error se propaga hacia atrás a

través de la red para cada neurona, y en consecuencia los pesos de conexión se ajustan.

La retro propagación es un método de primer orden basado en el descenso de gradiente más pronunciado, donde la dirección del vector se establece igual al vector gradiente. En consecuencia, la solución a menudo sigue un camino en zigzag al tratar de llegar a una posición de error mínimo, lo que puede retrasar la finalización del proceso. También es posible que el proceso de formación pueda quedar atrapado en un mínimo local.

Véase el Anexo 12.4.2 RNAs para la derivación del algoritmo retro propagación y el Anexo 12.4.4 RNAs para una descripción paso a paso del algoritmo de retro propagación.

Algoritmos de gradiente conjugado

El método del gradiente conjugado es una técnica numérica bien conocida usada para la solución de diversos problemas de optimización. Es ampliamente utilizada, ya que representa un buen compromiso entre simplicidad del algoritmo de máxima pendiente y la convergencia rápida del método de Newton. Se han desarrollado muchas variaciones del algoritmo de gradiente conjugado, pero su forma clásica se discute más adelante y en el Anexo 12.4.4.

El método del gradiente conjugado, a diferencia del de retro propagación estándar, no procede a lo largo del dirección del gradiente de error, sino en una dirección ortogonal a la que tuvo en el paso anterior. Esto evita que la reducción al mínimo alcanzado durante el paso actual influya en los pasos futuros. Está comprobado que cualquier método de minimización desarrollado por el algoritmo de gradiente conjugado es cuadráticamente convergente.

Algoritmos Cuasi - Newton

De acuerdo con el método de Newton, el conjunto de ponderaciones óptimas que minimiza la función de error puede ser encontrado mediante la aplicación de la siguiente ecuación

Ecuación nº 8.12

$$w(k + 1) = w(k) - H_k^{-1} \cdot g_k$$

donde H_k es la matriz de Hesse (segunda derivada) del índice de rendimiento a los valores actuales de los pesos y sesgos:

Ecuación nº 8.13

$$H_k = \nabla^2 E(w)_{w=w(t)}$$

y g_k representa el gradiente de la función de error:

Ecuación nº 8.14

$$g_k = \nabla^2 E(w)_{w=w(k)}$$

El método de Newton puede (teóricamente) converger más rápido que los métodos de gradiente conjugado. Desafortunadamente, la naturaleza compleja de la matriz hessiana puede necesitar un alto consumo de recursos para calcularla.

Los métodos de Cuasi-Newton ofrecen una solución a este problema con menos requisitos computacionales, actualizan una matriz hessiana aproximada en cada iteración del algoritmo, acelerando así cálculos durante el proceso de aprendizaje.

El Anexo 12.4.5 contiene un algoritmo de paso a paso a partir de un algoritmo típico cuasi-Newton, a saber, el algoritmo Broyden-Fletcher-Goldfarb-Shanno(BFGS)

Algoritmo de Levenberg-Marquardt

Al igual que los métodos cuasi-Newton, el algoritmo de Levenberg-Marquardt fue diseñado para incrementar la velocidad de formación de la RNA sin tener que calcular la matriz de Hesse. Si la función rendimiento tiene la forma de una suma de cuadrados, entonces la matriz de Hesse se puede aproximar como

Ecuación nº 8.15

$$H = J^T \cdot J$$

y el gradiente puede calcularse como

Ecuación nº 8.16

$$g = J^T \cdot e$$

donde J es la matriz Jacobiana y e es un vector de los errores de la red.

La matriz Jacobiana contiene primeras derivadas de los errores de la red con respecto a los pesos y sesgos. La matriz Jacobiana es menos complejo de resolver que la matriz de Hesse.

Un problema de este método es que requiere la inversión de la matriz J , que puede ser no invertible o incluso singular. Este problema puede resolverse fácilmente mediante la siguiente modificación:

Ecuación nº 8.17

$$H = J^T \cdot J + \mu \cdot I$$

donde μ es un número pequeño e I es la matriz identidad.

Este método representa una transición entre el método de la máxima pendiente y el método de Newton. Ello hace un intento de combinar los puntos fuertes de ambos métodos (convergencia inicial rápida y convergencia rápida / precisa cerca de un mínimo de error, respectivamente) en un algoritmo.

Algoritmo QuickProp

El QuickProp algoritmo, desarrollado por Fahlman [42], es una modificación del algoritmo de retropropagación. Es un método de segundo orden basado en el método de Newton. El procedimiento de actualización de pesos, depende de dos aproximaciones: primero, que los pequeños cambios en un peso tienen relativamente poco efecto en el gradiente de error observado en otros pesos; segundo, que la función de error con respecto a la cada peso es localmente cuadrática. QuickProp trata de saltar hasta el punto mínimo de la función cuadrática. Este nuevo punto probablemente no será el mínimo, sino como un solo paso en un proceso iterativo algoritmo, el algoritmo parece que funciona muy bien, de acuerdo con Fahlman y Lebiere [43].

Algoritmo de Correlación en cascada

Fahlman y Lebiere desarrollaron el algoritmo de Correlación-Cascada en 1989. El algoritmo de correlación en cascada es un meta-algoritmo o algoritmo constructivo. El algoritmo no sólo entrena a la red, minimizando el error de red mediante el ajuste de los parámetros internos, sino que también encontrar una arquitectura de red óptima mediante la adición de las neuronas para la red.

El ciclo de formación de la RNA se divide en dos fases. En primer lugar, las neuronas de salida están capacitados para minimizar el error total de salida. A continuación, se inserta una nueva neurona (una denominada neurona candidato) y se conecta a cada neurona de salida y todas las neuronas en la capa anterior (añadiendo una nueva capa a la de red). La neurona candidata está capacitada para correlacionar con el error de salida. La adición de nuevas neuronas candidatos se continúa hasta que se obtiene la correlación entre las neuronas y el error de salida.

En lugar de entrenar la red para maximizar la correlación entre la salida de las neuronas y el error de salida, también se puede optar por entrenar para minimizar el error de salida de la RNA.

8.5 Representación del entorno

El modelo del entorno, en el cual una RNA existe, es una función estocástica variable en el tiempo sobre el espacio de patrones de entrada. Es decir, nos imaginamos que en cualquier punto en el tiempo, hay una cierta probabilidad que alguno de los posibles conjuntos de patrones de entrada influyan sobre las unidades de entrada. Esta función de probabilidad puede, en general, depender del historial de las entradas al sistema, así como el de las salidas del sistema.

8.5.1 Capacidades de mapeo de funciones de RNAs

La aproximación de las funciones matemáticas se refiere a menudo como función de mapeo. La mayoría de aplicaciones hacen uso de las capacidades de mapeo de las RNA. Este estudio proporciona más detalle de correlación de funciones ya que este es también el foco principal de esta investigación.

Después de una introducción sobre correlación de funciones, se analizarán dos tipos de redes de mapeo: redes estándar feedforward y redes de función de base radial. La aplicación en la dimensión de tiempo de las RNAs se discute en 8.5.4

Correlación de funciones

La tarea de direccionamiento de las RNAs con capacidades de mapeo es la implementación aproximada de un mapeo acotado o función $f: A \subset \mathfrak{R}^n \rightarrow \mathfrak{R}^m$, de un subconjunto limitado A Espacio euclidiano n – dimensional a un subconjunto acotado $f[A]$ espacio euclidiano de m -dimensional, por medio de ejemplos de entrenamiento $(\mathbf{x}_1, \mathbf{t}_1), (\mathbf{x}_2, \mathbf{t}_2), \dots, (\mathbf{x}_k, \mathbf{t}_k)$, de la acción de mapeado, donde $\mathbf{t}_k = f(\mathbf{x}_k)$. Las redes de mapeo también pueden manejar casos donde se añade ruido a la función que se ajusta.

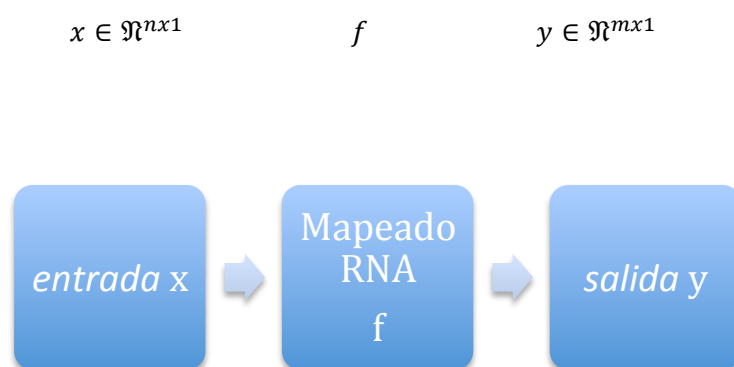


Figura nº 8.13 Estructura general para la función de mapeado de las RNAs.

La precisión de aproximación de un mapeo RNA se mide mediante la comparación de su salida (y) para una cierta señal de entrada (x) con los valores objetivo (t) del conjunto de datos.

Un modelo de regresión lineal simple, por ejemplo, se basa en una forma funcional lineal estimada, a partir del cual se producen variaciones por diferentes pendientes y los parámetros de intersección, los cuales se determinan utilizando el conjunto de datos de la construcción. La forma de la función sesgada y las variaciones de los mismos en un modelo de RNA están tan bien definidos:

35. Las técnicas de análisis de regresión requieren del investigador el elegir la forma de una función para ser ajustada a los datos, mientras que las técnicas RNA no lo hacen.
36. Las RNAs tienen muchos parámetros internos más libres (cada peso entrenable) que los modelos estadísticos correspondientes (como resultado, son tolerantes a la redundancia).

Lo importante es darse cuenta de que en ambos casos no se dará a conocer la forma de la función f explícitamente. La forma de la función se representa implícitamente en los parámetros de pendiente y de intersección en el caso de análisis de regresión lineal y en los parámetros internos de la red en el caso de las RNAs.

Hay varios tipos de RNAs que puede designarse como redes de mapeo. Sin embargo, se seguirá a la definición estricta de las redes de mapeo presentados anteriormente. Esto resulta en una exclusión, por ejemplo, de las llamadas redes lineales asociadoras (que pueden ser vistas como redes de mapeo simplificado) y los llamados mapas auto-organizados (que se puede ver como variantes del aprendizaje no supervisado de redes de mapeo estándar).

Las dos subsecciones siguientes se centrarán únicamente en los RNAs de correlación de funciones más utilizadas: Las redes feedforward estándar, las redes de función de base radial y las redes temporales (10).

8.5.2 Redes feedforward estándar

La mayoría de las redes de mapeo se pueden designar como redes feedforward estándar. El número de variaciones de estas RNAs es inmensa.

La característica más importante de las redes feedforward estándar es que los únicos tipos de conexiones durante la fase de aprendizaje son conexiones feedforward

(10) Existen otras RNAs que presentan capacidades de mapeo (por ejemplo, la red contrapropagación [Hecht-Nielsen, [41]], pero han hecho caso omiso de aquí porque rara vez se utilizan

(explicado en 8.4.5). Debe de tenerse a en cuenta que durante la fase de aprendizaje existen conexiones de retroalimentación para propagar errores de salida de nuevo en la RNA (como se explica en **Error! Reference source not found.**).

Una red feedforward estándar puede ser construida a partir de cualquier número de capas ocultas, o puede sólo tener unidades de entrada y una capa de salida. El algoritmo de entrenamiento utilizado puede ser cualquier tipo de algoritmo de aprendizaje supervisado. Todos los demás parámetros de arquitectura RNA (número de neuronas en cada capa, la función activación, el uso de una neurona sesgo, etcétera) puede variar.

Perceptrones multicapa (MLP)

Las redes feedforward con una o más capas ocultas a menudo se tratan en la literatura como perceptrones multicapa (MLP). Este nombre indica que estas redes se componen de perceptrones (nombrados después perceptron neuroordenador desarrollado en la década de 1950, discutida en 8.3.3).

El perceptrón clásico es una neurona que es capaz de separar dos clases basándose en ciertos atributos de la entrada de la neurona. La combinación de más de un perceptrón da como resultado una red que es capaz de hacer clasificaciones más complejas. Esta capacidad de clasificar está basada parcialmente en el uso de una función de activación de limitador duro (véase 8.4.7). La función de activación de las neuronas en las redes feedforward, sin embargo, no está limitada a las funciones del limitador duro simplemente; las funciones sigmoideas o lineales, se utilizan también a menudo. Y a menudo hay otras diferencias entre los perceptrones y otros tipos de neuronas. De esto podemos concluir de que el nombre MLP para redes feedforward de múltiples capas que consta de neuronas regulares es básicamente incorrecto.

Redes de retro propagación (BPN)

Las redes feedforward se refieren a veces con un nombre que se deriva del propio algoritmo de entrenamiento. La regla de aprendizaje más común es el algoritmo de retro propagación. Un RNA que utiliza este algoritmo de aprendizaje se refiere en consecuencia como una red de retro propagación (BPN).

Hay que tener en cuenta, sin embargo, que los diferentes tipos de RNAs (aparte de las redes feedforward) también puede ser entrenadas con el algoritmo retro propagación. Estas redes no deben ser referidas como redes de retro propagación, en aras de la claridad. Nos referiremos pues a una RNA tal que por su nombre propio: la red feedforward con aprendizaje o entrenamiento por retro propagación.

8.5.3 Redes función de base radial (RBF)

La red de función de base radial (RBF) es una variante de la red de alimentación directa estándar. Puede ser considerada como una red de alimentación directa de dos capas en la que la capa oculta realiza una transformación no lineal fijo sin parámetros internos ajustables. La capa de salida, que contiene sólo los pesos ajustables en la red, a continuación, combina linealmente las salidas de las neuronas ocultas [44]. La red RBF

es entrenada por la determinación de los pesos de conexión entre la capa oculta y la salida a través de un algoritmo de entrenamiento de alto rendimiento.

La capa oculta se compone de un número de neuronas y vectores de parámetros internos llamados "centros", que pueden considerarse los vectores de peso de las neuronas ocultas. Cada muestra de entrenamiento presentado a la red añade una neurona.

La entrada para cada neurona en esta capa es igual a la distancia euclidiana entre el vector de entrada y su vector de peso (centro), multiplicado por el sesgo de la neurona. La función de transferencia de la base radial de neuronas normalmente tiene una forma de Gauss (véase 8.4.7). Esto significa que si la distancia entre el vector de entrada y el centro disminuye, aumenta la salida de la neurona (con un máximo de 1). En contraste, las neuronas radiales básicas con vectores de peso son muy diferentes a partir del vector de entrada tienen, salidas cercanas a cero. Estas pequeñas salidas sólo tienen un efecto insignificante en las neuronas de salida lineales.

Si una neurona tiene una potencia de 1, se pasan los valores de peso entre la capa oculta y de salida a las neuronas de salida lineales. De hecho, si sólo una neurona radial base tiene una potencia de 1, y todos los demás tiene salidas de 0 (o muy cerca a 0), la salida de la capa de salida lineal serían los pesos entre la neurona activa y la capa de salida. Esto, sin embargo, es un caso extremo. Típicamente varias neuronas siempre están contribuyendo, en diversos grados.

Resumiendo, la RBF determina la semejanza entre un vector de entrada y la red de centros. En consecuencia produce una salida basada en una combinación de las neuronas activadas (es decir, los centros que muestran una semejanza) y los pesos entre estas neuronas ocultas y la capa de salida.

La principal diferencia entre la red RBF y retro propagación radica en la naturaleza de las no linealidades asociadas con neuronas ocultas. La no linealidad en retro propagación es implementada por una función fija tal como una sigmoidea. El método RBF, por otra parte, basa sus no linealidades en el conjunto de los datos de entrenamiento. El método RBF original requiere que existan muchos centros RBF (neuronas) como puntos de datos de entrenamiento, que rara vez se da en la práctica, ya que el número de puntos de datos no suele ser muy grande [44]. Una solución a este problema es para monitorizar el error total de la red, durante la presentación de datos de entrenamiento (la adición de las neuronas), y poner fin a este procedimiento cuando el error no disminuye significativamente.

Las redes RBF son generalmente capaces de alcanzar el mismo rendimiento que las redes feedforward mientras aprenden más rápido. En el lado negativo, se necesita más datos para llegar a la misma precisión que redes en las feedforward. Según Chen, Cowan y Grant [44], el rendimiento de la red RBF depende fundamentalmente de los centros que resultan de la formación de datos introducidos. En la práctica, los datos de

formación se eligen a menudo para ser un subconjunto de los datos totales, que convenientemente muestras del dominio de entrada.

8.5.4 RNAs temporales

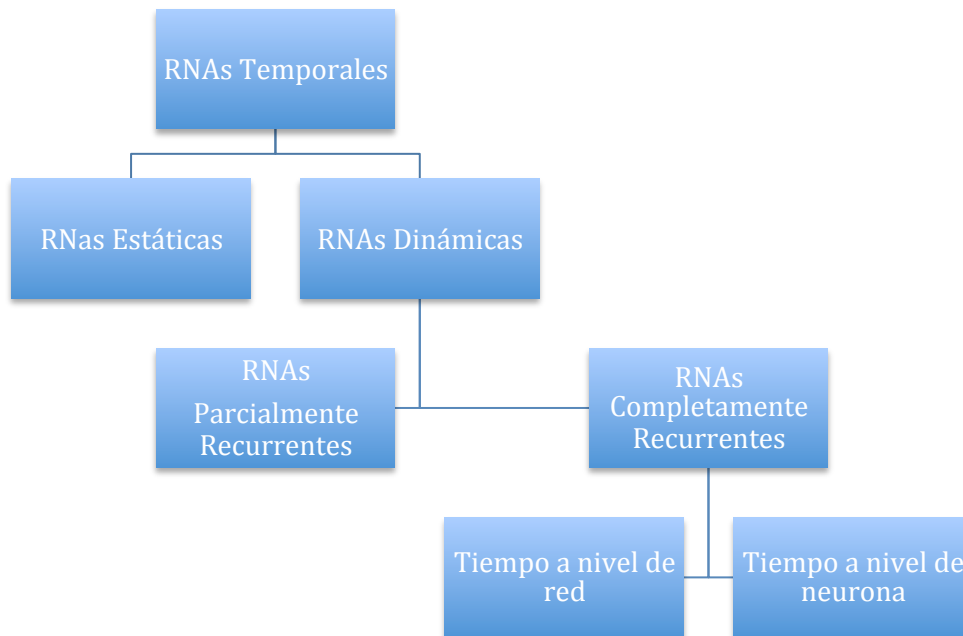


Figura nº 8.14 Clasificación de modelos de RNAs con respecto al tiempo de integración.

Cuando una función de mapeo RNA intenta aproximar una función dependiente del tiempo, la dimensión del tiempo debe ser incorporada en la red para un rendimiento óptimo.

Los modelos de RNA en los que la dimensión temporal se implementa de una manera u otra se llaman RNAs temporales.

Con respecto a la integración de la dimensión de tiempo en los modelos de RNA, la primera opción no es introducirlo, sino dejar el tiempo fuera de la arquitectura de la RNA (red estática). Los modelos que incorporan este método se llaman modelos de línea de retardo con tomas. Este método se reduce a la introducción de una ventana de series de entrada a una red, es decir, $\mathbf{P}(t)$, $\mathbf{P}(t-1)$, ..., $\mathbf{P}(t-m)$.

$\mathbf{P}(t)$ representa una de las entradas en el tiempo t y m la longitud de la memoria. El total de neuronas de entrada aumenta con la longitud de la memoria utilizada. La presentación de una RNA con una línea de retardo con tomas básicamente significa que el patrón temporal se convierte en un patrón espacial, que luego puede ser aprendido por una red estática.

Este método también se puede combinar con uno de los tipos de red dinámicas que se discuten a continuación.

La introducción de la dimensión de tiempo en un modelo neuronal mediante su incorporación en la arquitectura RNA (red dinámica) se puede hacer en varios niveles. En primer lugar, el tiempo se puede utilizar como un índice de los estados de la red. Se conserva el estado precedente de las neuronas y es reintroducido en el siguiente paso en cualquier punto de la red. El orden es la única propiedad de tiempo utilizado cuando se trabaja con estas secuencias. Esto es una representación del tiempo en los modelos. Este método básicamente significa que las neuronas de una capa dentro de una RNA se puede conectar a las neuronas de la capa anterior, la capa siguiente y la propia capa. Este tipo de modelos se conocen como modelos de contexto o modelos parcialmente recurrentes.

Debe tenerse en cuenta que actualización la del peso para un modelo de contexto no es local, en el sentido de que la actualización de un solo peso requiere la manipulación de toda la matriz de pesos, que a su vez aumenta el esfuerzo y el tiempo computacional.

Un paso más en la introducción de la dimensión temporal en una RNA es representar de forma explícita el tiempo en el nivel de la red, es decir, mediante la introducción de algunos retrasos de propagación (pesos de tiempo) en las conexiones y/o mediante la introducción de memorias en el nivel de la propia neurona. Estos modelos se conocen como modelos completamente recurrentes. Os algoritmos para capacitar a estos modelos dinámicos son significativamente más complejos en términos de requerimiento de tiempo y almacenamiento.

En el caso de la aplicación de tiempo a nivel de red, la RNA utiliza la combinación de una serie de valores que representan la fuerza de la conexión entre dos neuronas de capas consecutivas (en lugar de un solo valor de peso), y los retrasos internos. Los elementos de la matriz son los pesos para el valor actual y anterior de la entrada a la neurona. Dicha matriz se llama una respuesta impulsiva finita (FIR).

Debido a las conexiones recurrentes en redes dinámicas, las variaciones de la formación deben emplearse algoritmos diferentes a la hora de entrenar a una red dinámica. Dos ejemplos bien conocidos de algoritmos de aprendizaje y de la dinámica son el algoritmo retro propagación con el tiempo (BPTT) y el algoritmo recurrente de aprendizaje en tiempo real (RTRL).

La Figura nº 8.14 muestra los tipos más comunes de redes temporales.

8.5.5 Red neuronal con tiempo de retardo (TDNN)

La TDNN es en realidad una red multicapa de alimentación directa con las entradas a la red retrasado sucesivamente en el tiempo utilizando líneas de retardo. La Figura nº 8.15 muestra una sola neurona con múltiples retrasos para cada elemento del vector de entrada. Se trata de una neurona 'piedra angular' de TDNNs feedforward. Como el vector de entrada $\mathbf{x}(\mathbf{k})$ evoluciona en el tiempo, los últimos valores de \mathbf{p} son tomados en

cuenta en la neurona. Una secuencia temporal, o una ventana de tiempo, para la entrada se establece y que se puede expresar como

Ecuación nº 8.18

$$X = \{x(0), x(1) \dots x(m)\}$$

Dentro de la estructura de la neurona los valores pasados de la entrada son establecidos por el camino de los retardos de tiempo que se muestran en la Figura nº 8.15 (para $p < m$). El número total de pesos necesarios para la única neurona es $(p+1) n$.

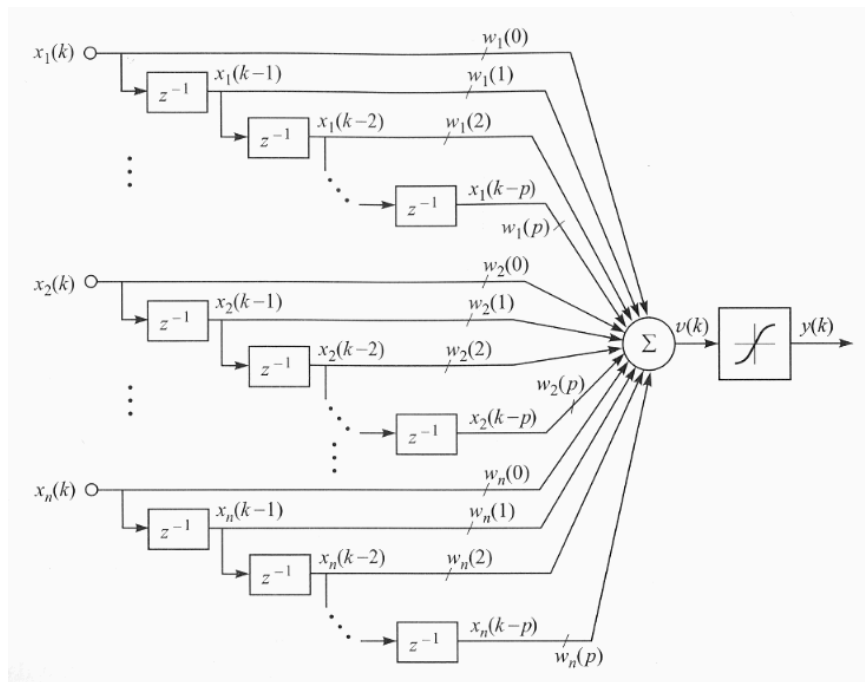


Figura nº 8.15 Neurona Básica TDNN con n conexiones de unidades de entrada y retardos en p cada señal de entrada (k es el índice de tiempo discreto) [45].

El modelo de una sola neurona se puede extender a una estructura multicapa. La estructura típica de la TDNN es una arquitectura en capas con demoras sólo en la entrada de la red, pero es posible incorporar retardos entre las capas.

8.5.6 Red neuronal feedforward con retraso de tiempo distribuido (DTLFNN)

En la DTLFNN el tiempo se distribuye en toda la arquitectura RNA por los pesos de tiempo sobre las conexiones de red internas. Opuesto al método implícito utilizado por redes parcialmente recurrentes, las DTLFNNs representan el tiempo de forma explícita en la arquitectura de red mediante respuestas impulso finito (FIR), representado en Figura 2.16. Las matrices de pesos de tiempo representado por el FIR pueden lograr vez efectos dependientes por medio de retardos internos de cada neurona.

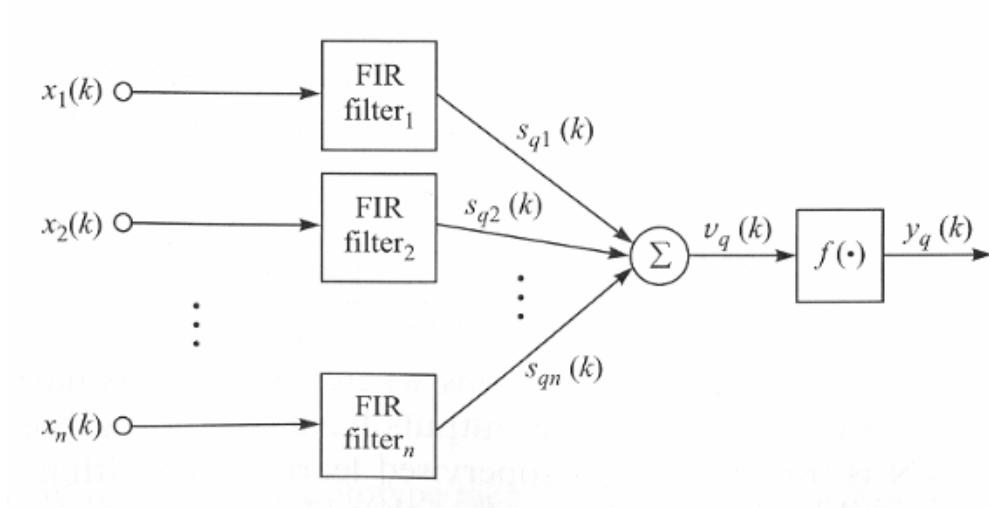



Figura nº 8.16 Filtro neurona no lineal [45]

8.5.7 Red recurrente simple (SRN)

La SRN se refiere a menudo como la red de Elman. Es una red feedforward con una sola capa oculta, excepto para las conexiones de retroalimentación desde la salida de las neuronas de la capa oculta a la entrada de la red.

Figura nº 8.17 La arquitectura neural SRN (donde z^{-1} es un retraso unidad de tiempo) [45]

Las unidades de contexto en la Figura nº 8.17 reproducen las señales de salida de la capa oculta en el instante anterior, es decir $\mathbf{x}'(\mathbf{k})$. El propósito de estas unidades de contexto es tratar con un patrón de entrada en disonancia. La retroalimentación proporcionada por estas unidades, básicamente, establece una estructura para la señal de entrada $\mathbf{x}(\mathbf{k})$. Esto puede proporcionar un mecanismo dentro de la red para discriminar entre los patrones que ocurren en diferentes momentos que son esencialmente idénticos.

Los pesos de las unidades de contexto permanecen fijos. Los otros pesos de la red, sin embargo, pueden ser ajustado utilizando el algoritmo retro propagación.

8.5.8 Predicciones adelantadas multi-paso

Un tema que está estrechamente relacionado con la aplicación de tiempo en el RNA es el de hacer predicciones para más de un tiempo p de pasos por delante. Cuando la predicción de tiempo p pasos por delante, por ejemplo, el mismo principio se puede utilizar como cuando la predicción de un solo paso de tiempo por delante. En lugar de la formación de una RNA con $t+1$ como objetivos, se pueden utilizar los valores de variables en t valores $t+p$. El resultado es una sola etapa p -paso por delante de la predicción. Sin embargo, como Duhoux [46] menciona, esto introduce un vacío de información, ya que todos (estimado) de información para pasos de tiempo $t+1 \dots t+p-1$ no se utiliza $p-1$. En este caso, es mejor que depender de métodos de predicción por delante de varios pasos, varios de los cuales se discutirán a continuación.

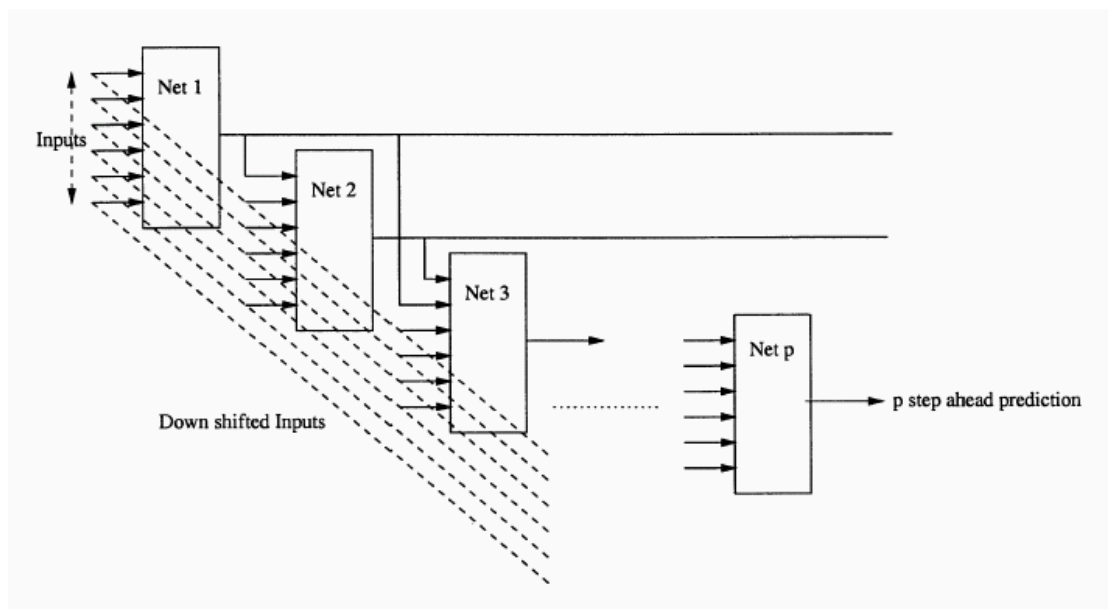


Figura nº 8.18 El método de varios pasos recursiva. Nuevas salidas estimadas se desplazan a través del vector de entrada y las entradas antiguas se descartan. Todas las redes neuronales son idénticas. [46]

8.5.9 Método recursivo de varios pasos (también denominado: predicción reiterada);

La red sólo tiene una neurona de salida, la previsión de un solo paso de tiempo por delante, se aplica de forma recursiva, usando las predicciones anteriores como entradas para las posteriores previsiones (Figura nº 8.18). Este método ha demostrado ser útil para métodos de modelización locales, pero si se adopta un enfoque de modelado global de este método puede estar plagada de errores por acumulación [47].

8.6 Encadenamiento de RNAs;

También se puede encadenar varios RNAs para hacer una predicción multi-paso por delante (Figura 2.19). Por un horizonte temporal de p , una primera red aprende a predecir en $t + 1$, a continuación, una segunda red es entrenada para predecir en $t + 2$ mediante el uso de la predicción proporcionada por la primera red como una entrada suplementaria. Este procedimiento se repite hasta que el horizonte de tiempo deseado p es alcanzado. [47]

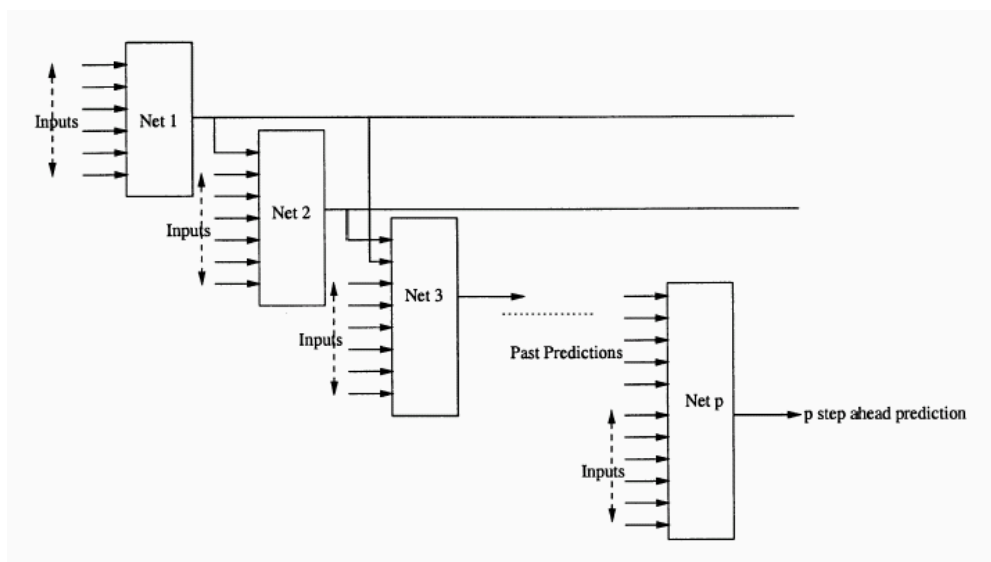


Figura nº 8.19. Las cadenas de RNAs: comenzando con una clásica de un predictor de un paso por delante, la salidas se insertan en siguiente predictor de una sola etapa, mediante la adición de la predicción de un solo paso por delante para el vector de entrada del predictor subsiguiente. [46]

8.6.1 Método de multi pasos directo.

El modelo RNA también puede entrenar de forma simultánea tanto el paso único como varios pasos por delante en el problema de predicción.




Figura nº 8.20 Método multipaso directo. La RNA que se utiliza es a menudo una red temporal de algún tipo.

La red tiene varias neuronas en la capa de salida, cada una de las cuales representa un paso de tiempo que será pronosticado (Figura nº 8.20). No puede haber tantas como neuronas de salida p . La capacitación se realiza mediante el uso de un algoritmo que castiga la predicción por acumulación de errores en la predicción por delante multi-etapa.

8.7 Aspectos de rendimiento de las RNA

Esta sección en primer lugar, proporciona una visión general de los aspectos positivos y negativos de las técnicas RNA, los cuales han sido encontradas por las aplicaciones históricas de RNAs. En segundo lugar, se discute uno de los problemas encontrados en relación con las técnicas RNA: el sobre entrenamiento. La sección relativa del sobre entrenamiento (8.7.2) no sólo ayuda en una comprensión adicional del problema y de ese modo el sobre entrenamiento la prevención de este problema, sino que también proporciona ideas que conducen a una comprensión más profunda de RNA técnicas de formación en general. Un fenómeno que está estrechamente relacionado con el sobre entrenamiento es el infra ajuste infra ajuste y se discute en (8.7.3)

8.7.1 Ventajas y desventajas de las RNA

Las aplicaciones anteriores de RNAs en diversos campos de trabajo han dado una visión de las ventajas y desventajas de las técnicas RNA, a diferencia de otras técnicas de modelado. En esta sección se presenta una breve descripción de las fortalezas y limitaciones que han demostrado ser universal para las RNAs.

Zealand, Burn y Simonovic [48] afirman de que las RNA tienen las siguientes características:

37. Deducen soluciones de datos sin el conocimiento previo de las regularidades en los datos; ellos extraer las regularidades empíricamente. Esto significa que cuando se utilizan técnicas de RNA en un determinado campo de trabajo, se

exige relativamente poco conocimiento específico de ese campo para el desarrollo de ese modelo debido a la naturaleza empírica de las RNA. Esta demanda es, sin duda mayor en el desarrollo de modelos que usen las técnicas de modelado convencionales.

38. Estas redes aprenden las similitudes entre los patrones directamente a través de ejemplos. Las RNAs puede modificar su comportamiento en respuesta al medio ambiente (es decir, se muestra un conjunto de entradas con correspondientes salidas deseadas, se auto-ajustan para producir respuestas coherentes). Las RNAs pueden generalizar a partir de ejemplos anteriores a los nuevos. La generalización es útil porque los datos del mundo real son ruidosos, distorsionados ya menudo incompletos.
39. Las RNAs también son muy buenas en la abstracción de las características esenciales de las entradas que contengan datos irrelevantes.
40. Son no lineales, es decir, que pueden resolver algunos problemas complejos con más precisión que las técnicas lineales.
41. Las RNAs contienen muchas operaciones idénticas e independientes que se pueden ejecutar al mismo tiempo, por lo que a menudo son bastante rápidas.
42. Como se mencionó anteriormente, las RNA pertenecen a la familia de sistemas de procesamiento distribuido en paralelo, que son conocidos por ser más rápido que los modelos convencionales. Esto es por supuesto dependiente de la eficiencia de la RNA.

Las RNAs tienen varios inconvenientes para algunas aplicaciones también [48]:

-Las RNAs pueden fallar a la hora de producir una solución satisfactoria, tal vez porque no hay función de aprendizaje adecuada o porque el conjunto de datos es insuficiente en tamaño o calidad.

El conjunto óptimo de datos de entrenamiento, la arquitectura óptima de la red, y otros parámetros diseño de la RNA del no pueden ser conocidos de antemano. Un buen modelo de RNA en general que se obtiene mediante el uso de un proceso de ensayo y error.

-Las RNAs no son muy buenas extrapoladoras . El rendimiento de la red se deteriora predecir valores que están fuera del rango de los datos de entrenamiento es generalmente inevitable. El pre-procesamiento datos (discutidos en 8.5.2) pueden ayudar a reducir esta caída de rendimiento

Las RNAs no pueden hacer frente a importantes cambios en el sistema, ya que están capacitadas (calibradas) en unos datos históricos establecidos y se supone que la

relación aprendida será aplicable en el futuro. Si se producen cambios importantes en el sistema, la red neural tendría que ser ajustada para el nuevo proceso.

Es imposible saber de antemano qué conjunto de parámetros de la red interna (es decir, colección de pesos de la red) es la configuración óptima para un problema. Los algoritmos de entrenamiento suelen hacer un buen trabajo de la búsqueda de un conjunto de parámetros que funciona bien, pero esto no es siempre el caso, por ejemplo, cuando se enfrenta con una superficie de error muy compleja para un problema. Además de este problema, también es muy difícil decir si un algoritmo de entrenamiento ha encontrado un local o un mínimo global.

La Tabla nº 8.3 muestra una revisión superficial de características RNA

Tabla nº 8.3 Detalle del rendimiento de las RNAs en algunos de sus aspectos [49]

Aspecto	Rendimiento RNAs	Sin embargo ...
Precisión	Alta	Necesita datos de aprendizaje exhaustivos.
Claridad / transparencia Baja	Baja	Existen algunos métodos analíticos matemáticos para hacer análisis de sensibilidad
La velocidad de respuesta	Alta	
Escalabilidad	Moderada	Depende de la complejidad del problema y disponibilidad de datos
La compacidad	Alta	-
Flexibilidad	Alta	Necesidades de datos de entrenamiento representativo
Incrustabilidad	Alta	-
Facilidad de uso	Moderada	-
La tolerancia para los datos dispersos	Alta	-
La tolerancia para el ruido en los datos	Moderado-Alta	El pre procesamiento puede ser muy útil en el tratamiento con el ruido
Independencia de los expertos	Alto	-
Velocidad de desarrollo	Moderada	Depende de la comprensión del proceso, de la velocidad de la computadora, y del método de aprendizaje
Tolerancia para la complejidad	Alta	-
Recursos informáticos	Baja – moderada	Escala con respecto a la cantidad de datos y el tamaño de red. Una RNA entrenada necesita pocos recursos de cálculo para ejecutarse.

Otro problema es que para diferentes períodos de tiempo o para diferentes procesos dominantes existentes en el conjunto de entrenamiento, es probable que haya conjuntos de parámetros diferentes que den un buen ajuste para los datos de prueba de cada instantes de tiempo. Los diferentes óptimos pueden entonces estar en muchas partes diferentes del espacio de parámetros, haciendo muy complicado la elección de la "óptima" RNA.

La falta de explicación de los resultados del modelo RNA es una de las principales razones que justifican una actitud escéptica hacia la aplicación de técnicas de RNA en ciertos campos. La falta de conceptos físicos y las relaciones es una razón por la que muchos científicos que miran a las RNAs con ojos de Argos '. La mayoría de las aplicaciones de RNA han sido incapaces de explicar en un sentido amplio la forma por la cual las RNAs llegan a una decisión.

8.7.2 Sobre entrenamiento

Un problema frecuente en la aplicación de técnicas de RNA se denomina sobre entrenamiento. El sobre entrenamiento normalmente es el resultado de una combinación de tres factores:

43. Uso de una arquitectura RNA, que es demasiado compleja para las relaciones que van a ser modeladas.
44. La formación excesivamente repetitiva de una RNA.
45. El entrenamiento de un RNA utilizando un conjunto de datos de entrenamiento inadecuado.

El punto primero es básicamente un problema de parametrización que también se encuentra en otros campos de modelado. La mejor aproximación para un modelo se puede realizar con un número suficiente de diferentes conjuntos de valores de parámetros del modelo. La singularidad de las relaciones entre los resultados de los modelos y los parámetros determina el grado de parametrización de un modelo. La parametrización implica "perder el control" del significado de los parámetros del modelo debido a que el modelo tiene demasiados grados de libertad. Como resultado, se aumenta la incertidumbre a la salida del modelo.

Las posibles causas de sobre parametrización son:

46. Una tasa desequilibrada entre los parámetros y la información (por ejemplo, muchos parámetros para la poca información).
47. Ocurrencia de correlaciones entre los parámetros del modelo.
48. Una tasa desequilibrada de parámetros sensibles e insensibles del modelo (por ejemplo demasiados parámetros sensibles).

Los puntos segundo y tercero son motivos de exceso de entrenamiento, debido a un exceso de información similar sobre una RNA. El modelo RNA adapta sus parámetros internos a esta información, lo que resulta en un modelo rígido que tiene éxito en la aproximación de las relaciones presentes en los datos de entrenamiento, pero no logra aproximar las relaciones en otros conjuntos de datos con valores ligeramente diferentes.

Básicamente, la red ajusta sus parámetros internos basándose no sólo en las relaciones esenciales asociadas a los datos empíricos, sino también en efectos no deseados presentes en los datos. Esto puede resultar en un modelo con la mala capacidad de predicción. Estos efectos no deseados podrían estar asociados con cualquiera de las mediciones de ruido o cualquier otra característica de los datos asociados con las relaciones adicionales o fenómenos que no son de interés para el diseño de un modelo. [45]

Debido a que la red recoge y modela pequeñas pistas que son específicas los patrones de entrada/salida a partir de los datos de entrenamiento, el error de la red y el rendimiento disminuye durante la etapa de entrenamiento. En esencia, la red genera una aproximación que encaja exactamente con los datos de entrenamiento, incluso el ruido en ella [49]. Como resultado del sobre entrenamiento, la capacidad de generalización de la red disminuye.

La Figura nº 8.21 muestra un ejemplo de una RNA con sobre entrenamiento. Si el objetivo de la red fuera la de aproximar los datos de entrenamiento (es decir, la aproximación de las cruces en la figura), el modelo RNA funcionaría extraordinariamente. Sin embargo, el objetivo de la RNA no es sólo para aproximar los datos de entrenamiento, si no imitar el proceso subyacente. Las cruces en la figura representan las mediciones de una variable estocástica dependiente del tiempo. Dado que la formación de datos no es más que una muestra de los datos de longitud finita, las cruces representan solamente solo los valore de la variable estocástica que ha de ser estimada.

En este caso, la salida del proceso, que puede ser descrito por una variable estocástica dependiente del tiempo, se supone conocida. Esta salida es el resultado de ciertos valores de variables de entrada y describe una evolución de un proceso en el tiempo (es decir, es una serie temporal). En este caso se trata de una función seno.

Esto implica que si disponemos de un número infinito de mediciones de la variable de salida estocástica, dado los mismos valores a las variables de entrada, y las trazamos, veremos una serie temporal con un media periódica, es decir, la línea discontinua en la Figura nº 8.21 Esta es la línea que en realidad tiene que ser aproximada por el modelo RNA. Las únicas "pistas" que el modelo obtiene para completar esta tarea son los datos de entrenamiento (los valores de las variables de entrada y las cruces de entrenamiento).

Dado que el modelo RNA generalmente no tiene información sobre otros valores de entrada y salida, el resultado es un modelo rígido que sólo responde adecuadamente a valores que son muy similares a los datos de entrenamiento.




Figura nº 8.21 Una red con sobre entrenamiento tiende a seguir los ejemplos de entrenamiento y por lo tanto pierde su capacidad de generalizar (aproximación a función sinusoidal). [50]

Una posible solución para el problema de sobre-entrenamiento es mantener un segundo conjunto de datos por separado y utilizarlos para la comprobación periódica de la aproximación a la red de este conjunto frente a la aproximación del conjunto de entrenamiento. El mejor punto para detener el entrenamiento es cuando la red obtiene un aproximación buena en ambos conjuntos de datos (ver en la Figura nº 8.22).

La razón por la que este método dará lugar a un modelo con mejor rendimiento es que en lugar de depender de una sola medición de la variable de salida estocástica (solo los datos de entrenamiento), el modelo puede ahora adaptarse a dos mediciones. Si el modelo RNA hace un buen trabajo en ambos conjuntos de datos, esto significa que el modelo se aproxima a la media de estos dos mediciones. Por lo tanto, el modelo de aproximación es teóricamente más cercano a la media real de la variable de salida estocástica (la función seno) que cuando se aproxima usando una medición.

Haciendo uso de un segundo o tercer conjunto de datos de entrenamiento cruzado se mejorará (teóricamente) la capacidad de generalización de un modelo RNA. Este enfoque, sin embargo, a menudo se desaconseja, debido a su gran demanda de datos.

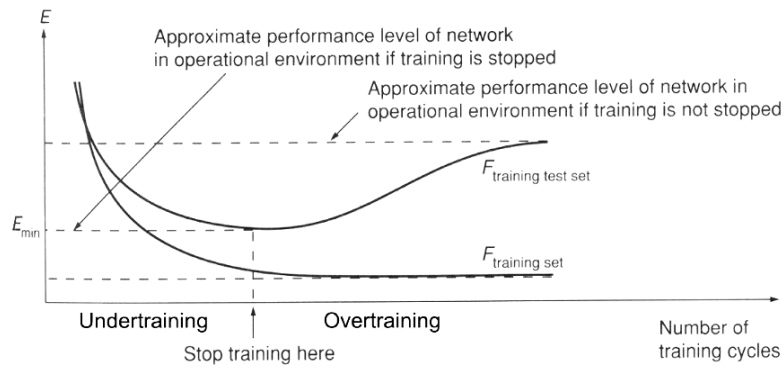


Figura nº 8.22 Eligiendo el número adecuado de ciclos de aprendizaje [41]

Otra forma posible de evitar el sobre entrenamiento se llama regularización. Este método implica la modificación de la función de error de algoritmos de aprendizaje rendimiento. Por ejemplo, si se utiliza como función de error, la generalización se puede mejorar mediante la adición de un término que consta de la media de la suma de los cuadrados de los pesos de la red y sesgos:

Ecuación nº 8.19

$$MSEREG = \gamma \cdot MSE + (1 - \gamma) \cdot MSW$$

dónde:

Ecuación nº 8.20

$$MSW = \frac{1}{n} \sum_{j=1}^n w_j^2$$

Utilizando esta función mejorará el rendimiento de la red para obtener pesos y sesgos más pequeños, y esto obligará a que la respuesta de la red sea más suave y menos propensa a sobre entrenar. [50]

Finalmente, se debe hacer una observación importante acerca de este debate sobre el sobre entrenamiento: la salida del proceso (es decir, la serie de "ideal" tiempo) será, en la práctica, a menudo desconocida. Por tanto, es imposible concluir si se produce sobre entrenamiento que se produzca una aproximación excesivamente precisa de los datos de entrenamiento.

Suponiendo que un modelo de RNA muestra buenos resultados de entrenamiento, pero no logra una alta precisión en otros conjuntos de datos, ¿cómo puede un desarrollador del modelo RNA si su modelo está sobre entrenado, o si el modelo es simplemente erróneo? Por desgracia, esta pregunta no se puede responder con certeza debido a la escasa transparencia del comportamiento del modelo RNA.

Sin embargo, como la teoría sobre el entrenamiento cruzado demuestra, este inconveniente no devalúa la importancia de mantener un conjunto de pruebas de formación independiente. Incluso si no se espera el sobre entrenamiento, aplicar entrenamiento cruzado es una buena elección, ya que reducirá el riesgo de que se produzca.

8.7.3 Infra ajuste

El infra ajuste (Underfitting) es otro efecto, estrechamente relacionado con el sobre entrenamiento, que se produce como resultado de entrenamiento incorrecto de una RNA. Si el entrenamiento de la red se detiene antes de que el error en los datos de entrenamiento y el entrenamiento cruzado de datos sea mínimo, la red no se aproximará de manera óptima a las relaciones entre estos datos. Una causa común de infra ajuste es que el modelado detiene el entrenamiento demasiado temprano, por ejemplo mediante el establecimiento de un número máximo de etapas de entrenamiento demasiado bajo, o un objetivo de error de entrenamiento que es demasiado alto. Además, un conjunto de datos pequeño debe utilizarse varias veces en la fase de entrenamiento para que una RNA tenga suficientes etapas para aprender las relaciones de estos datos.

Desde un punto de vista práctico, el infra ajuste es un efecto de menor importancia en la mayoría de las para RNAs entrenadas. La razón de esto es que los algoritmos de aprendizaje son a menudo incapaces de alcanzar el mínimo global de una función error compleja. E incluso si se alcanza este mínimo global, probablemente no tienen las mismas coordenadas (es decir, los valores de peso) como la función de error del entrenamiento y los datos de entrenamiento cruzado.

9 Modelos de red y optimización

9.1 Enfoque del Algoritmo Genético Multiobjetivo

9.1.1 Prefacio

La optimización del diseño de red es básicamente una cuestión fundamental en diversos campos, entre ellos las matemáticas aplicadas, la informática, la ingeniería, la administración y la investigación. Los modelos de red proporcionan una forma útil para modelar diversos productos y se utilizan ampliamente en muchos tipos diferentes de sistemas: las comunicaciones, la mecánica, la electrónica, la fabricación y en logística. Sin embargo, muchas aplicaciones prácticas imponen cuestiones más complejas, como la estructura, restricciones y múltiples objetivos que se manejan de forma simultánea y hacen que el problema sea insoluble desde los enfoques tradicionales.

Los avances recientes en los algoritmos de evolución (AE) se centran en cómo solucionar tales problemas prácticos de optimización de la red. Los algoritmos evolutivos (AE) son algoritmos estocásticos cuyas estrategias de búsqueda se modelan a partir de los fenómenos evolutivos naturales; la herencia genética y la lucha darwiniana por la supervivencia. Por lo general, es necesario diseñar un algoritmo orientado para los diferentes tipos de problemas de optimización de la red de acuerdo con la características del problema a tratar. Por lo tanto, la forma de diseñar algoritmos eficientes adecuados a la naturaleza compleja de los problemas de optimización de la red es el principal enfoque de este trabajo de investigación. En general, los AE implican la siguiente optimización meta heurística de algoritmos, tales como algoritmo genético AG, la programación evolutiva (EP), la estrategia de evolución (ES), la programación genética (GP), el aprendizaje de los sistemas clasificador (LCS), y la inteligencia de enjambre (que comprende la optimización de colonia de hormigas): ACO y la optimización de enjambre partículas : PSO. Entre ellos, los algoritmos genéticos son quizás el tipo más conocido de los algoritmos evolutivos hoy.

En las últimas décadas, el estudio sobre la forma de aplicar los algoritmos genéticos a los problemas en el mundo de la ingeniería industrial ha despertado mucha curiosidad de muchos investigadores y profesionales en el área de ciencias de la administración, operaciones investigación e industrial e ingeniería de sistemas. Una razón importante es que los algoritmos genéticos son poderosos y aplicables ampliamente a la búsqueda estocástica y a las técnicas optimización, y funcionan bien para muchos problemas complejos que son muy difíciles de resolver mediante técnicas convencionales. Muchos de los problemas de ingeniería pueden ser considerados como un tipo de tipo de red basado en problemas de optimización sujetos a restricciones complejas.

Los algoritmos genéticos básicos generalmente no producen soluciones seleccionadas para estos problemas de optimización de ingeniería difíciles. Por lo tanto, la forma de adaptar algoritmos genéticos para satisfacer la naturaleza de estos problemas es un punto importante en esta investigación. El trabajo se destina a cubrir los principales temas de la investigación sobre la aplicación de la multiobjetivo algoritmos genéticos a diversos problemas de optimización de la red.

Estos problemas, tales como problemas de agenda en líneas de flujo, problemas de plantas de fabricación, programación de máquina robots, problemas de programación temporal, problemas de transporte, disposición de instalación en problemas de diseño, y otros temas en el diseño de ingeniería.

9.2 Algoritmos genéticos multiobjetivo

Muchos de los problemas del mundo real a partir de las operaciones de investigación (OI) / de la gestión de la ciencia (GC) son muy complejas en la naturaleza y es bastante difícil de resolver por las técnicas de optimización convencionales. Desde la década de 1960 ha habido un interés creciente en la imitación de los seres vivos para resolver ese tipo de problemas de optimización difíciles.

Simulando procesos evolutivos naturales empleando las técnicas de la optimización estocástica se desarrollan los llamados algoritmos evolutivos (AEs) que a menudo pueden superar a los métodos convencionales de optimización cuando se aplica a problemas difíciles del mundo real. Los AEs sobre todo involucran a algoritmos de optimización meta heurísticas como los algoritmos genéticos AG [51] (Holland) la programación evolutiva (PE) [52] (Fogel), estrategias de evolución (EE) (Rechenberg/Schwefwl), la programación genética (PG) [53], (Koza), los sistemas clasificadores de aprendizaje (SCA) la inteligencia de enjambre (que comprende la optimización de colonia de hormigas (OCH) [y la optimización del enjambre de partículas (OEP) Entre ellos, los algoritmos genéticos son quizás el tipo los más ampliamente conocido de algoritmos evolutivos utilizados en la actualidad.

9.2.1 Introducción

La forma usual de los algoritmos genéticos AG es descrita por Goldberg [54]. Los AGs son algoritmos de búsqueda estocásticos basados en el mecanismo de la selección natural y natural la genética, a diferencia de las técnicas de búsqueda convencionales, los AG comienzan con un conjunto inicial de soluciones aleatorias denominadas población que cumplan los límites y/o el sistema de restricciones al problema.

Cada individuo de la población se llama un cromosoma (o individuo), lo que representa una solución al problema en cuestión. El cromosoma es una [55] cadena de símbolos por lo general, pero no necesariamente, una cadena binaria de bits. Los cromosomas evolucionan a través de iteraciones sucesivas llamadas generaciones. Durante cada generación, los cromosomas se evalúan, utilizando algunas medidas de aptitud. Para crear el próxima generación, nuevos cromosomas, llamados descendencia, por cualquiera método de fusión, se forman dos cromosomas de la generación actual utilizando un operador de cruce o modificando un cromosoma, usando un operador de mutación. Una nueva generación se forma por la selección, de acuerdo a los valores de aptitud, con la aceptación de algunos de los padres y de los hijos, y el rechazo de otros con el fin de mantener el tamaño de la población constante. Los cromosomas adaptados tienen mayores probabilidades de ser seleccionados. Después de varias

generaciones, los algoritmos convergen al mejor el cromosoma, que esperamos representa la óptima o sub óptima solución al problema.

9.2.2 Estructura general de un Algoritmo Genético

En general, una AG tiene cinco componentes básicos, tal como se resume por Michalewicz [56]

1. Una representación genética de las posibles soluciones al problema.
2. Una forma de crear una población (un conjunto inicial de posibles soluciones).
3. Una función de evaluación de soluciones de calificación en cuanto a su estado físico.
4. Los operadores genéticos que alteran la composición genética de la descendencia (de cruce, mutación, selección, etc.).
5. Los valores de parámetros que utiliza el algoritmo genético (tamaño de la población, las probabilidades de la aplicación de operadores genéticos, etc.).

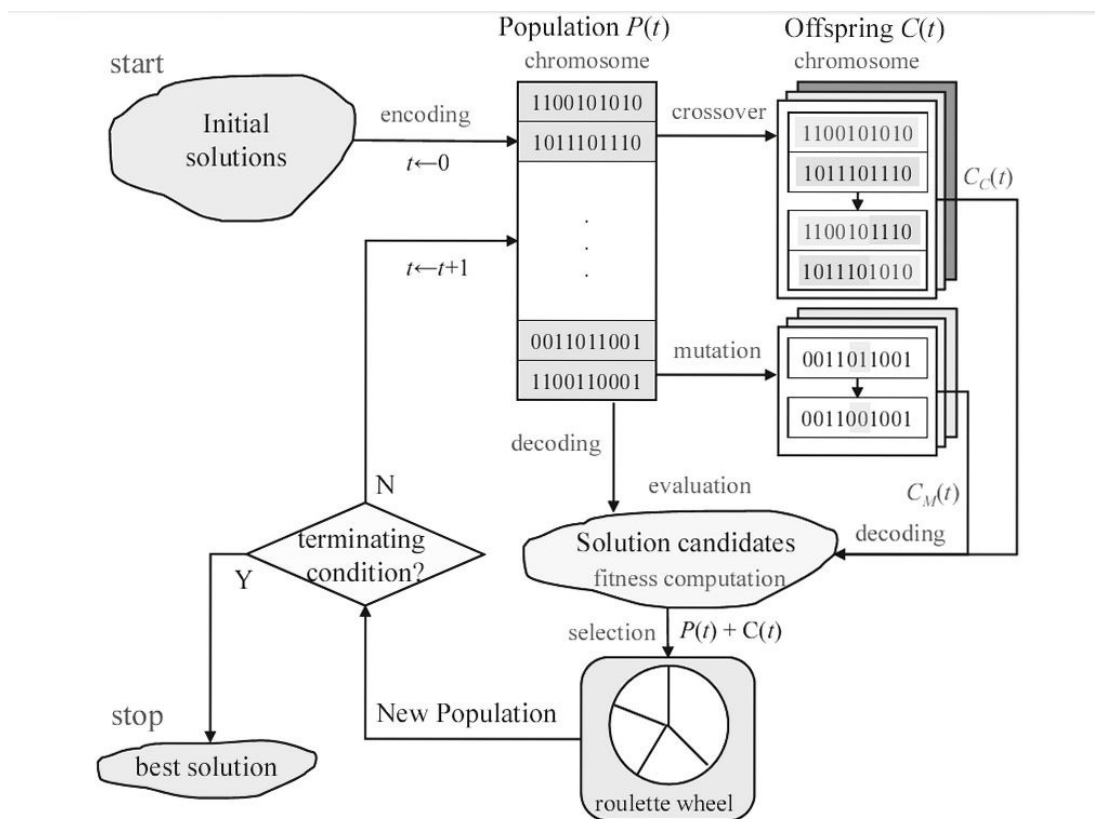


Figura nº 9.1 Estructura general de un algoritmo genético AG.

La Figura nº 9.1 muestra una estructura general de AG. Sea $P(t)$ y $C(t)$ padres e hijos de la generación actual t , respectivamente, y la estructura general de ejecución de un AG se describe como sigue:

Procedimiento nº 1 Algoritmo genético básico

```

procedure: basic GA
input: problema data, GA parameters
output: te best solution
begin
   $t \leftarrow 0$ ;
  initialize  $P(t)$  by encoding routine;
  evaluate  $P(t)$  by decoding routine
  while ( not terminating condition) do
    create  $C(t)$  from  $P(t)$  by crossover routine;
    create  $C(t)$  from  $P(t)$  by mutation routine;
    evaluate  $C(t)$  by decoding routine;
    select  $P(t+1)$  from  $P(t)$  and  $C(t)$  by selection routine;
     $t \leftarrow t+1$ ;
  end
output
end

```

9.2.3 Explotación y Exploración

La búsqueda es uno de los métodos de resolución de problemas más universales para los que no se puede determinar una secuencia previa de pasos que conduzcan a una solución. La búsqueda se puede realizar, ya sea con estrategias ciegas o estrategias heurísticas. Las estrategia de búsqueda a ciegas, no utiliza la información sobre el dominio del problema. La estrategias de búsqueda heurística, utiliza la información adicional para guiar la búsqueda desplazándola junto con las mejores direcciones de búsqueda.

Hay dos cuestiones importantes en las estrategias de búsqueda: aprovechar la mejor solución y explorar el espacio de búsqueda. Michalewicz dio una comparación sobre la búsqueda “*hillclimbing*” (*ascensión a la cúspide*), la búsqueda al azar y la búsqueda genética]. La *Hillclimbing* es un ejemplo de una estrategia que aprovecha la mejor solución para una posible mejora, ignorando la exploración del espacio de búsqueda. La búsqueda al azar es un ejemplo de una estrategia que explora el espacio de búsqueda, haciendo caso omiso de la explotación de las regiones prometedoras del espacio de búsqueda.

9.2.4 Búsqueda basada en la población

Generalmente, un algoritmo para resolver problemas de optimización es una secuencia de etapas de cálculo que asintóticamente convergen para una solución óptima. Los métodos de optimización mas clásicos generan una secuencia determinista de cálculo basado en las derivadas de orden superior de la función objetivo. Los métodos se aplican a un único punto en el espacio de búsqueda. El punto se mejora después a lo largo del sentido gradual descendente a través de iteraciones como se muestra en la

Figura nº 9.2 Esta aproximación, punto a punto abarca el peligro de fracasar en óptimos locales. El AG realiza una búsqueda multidireccional mediante el mantenimiento de una población de posibles soluciones. El enfoque población-a-población tiene la esperanza de hacer la búsqueda evitando óptimos locales. La población sufre una evolución simulada: en cada generación las relativamente buenas soluciones se reproducen, mientras que las relativamente malas soluciones mueren. El AG utiliza reglas de transición probabilística para seleccionar a alguien para ser reproducido y alguien para morir a fin de orientar su búsqueda hacia las regiones del espacio de búsqueda con probabilidades mejora.

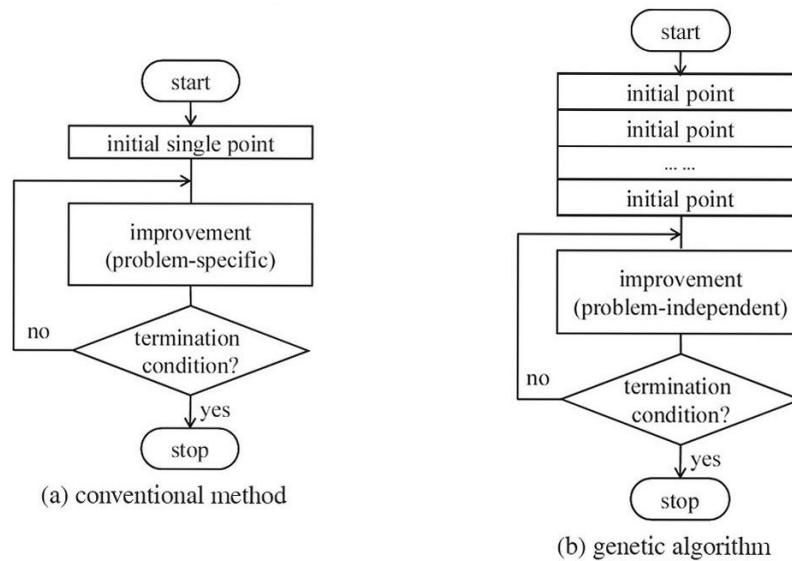


Figura nº 9.2 Comparación entre el método convencional y el planteamiento con algoritmo genético.

9.2.5 Ventajas Principales

Los AGs han recibido considerable atención en cuanto a su potencial como una nueva técnica de optimización. Hay tres grandes ventajas al aplicar los AG a la optimización de problemas:

Adaptabilidad: El AG no tiene mucha exigencia matemática respecto sobre los problemas de optimización. Debido a la naturaleza evolutiva, el AG buscará soluciones sin tener en cuenta el funcionamiento interno específico del problema. El AG puede manejar cualquier tipo de funciones objetivo y no tiene ningún tipo de restricciones, es decir, lineal o no lineal, que se define en discretas, espacios de búsqueda continuos o mixtos.

Robustez: El uso de los operadores de evolución hace el AG muy eficaz en el desempeño de una búsqueda global (en probabilidad), mientras que la mayoría de las búsquedas heurísticas convencionales normalmente realizan una búsqueda

local. Se ha demostrado por muchos estudios que el AG es más eficiente y más robusto en la localización de la solución óptima y reducen el esfuerzo computacional ante otras búsquedas heurísticas convencionales.

Flexibilidad: El AG nos proporciona una gran flexibilidad para hibridar el dominio dependiente heurístico para hacer una implementación eficiente sobre un problema específico.

9.2.6 Aplicación de los Algoritmos Genéticos

En la aplicación del AG, varios componentes deben ser considerados. En primer lugar, debe ser elegida una representación genética de las soluciones (es decir, la codificación); segundo, se aplica una función de mejora de la evaluación de las soluciones. (es decir, la decodificación); tercero, debe de estar diseñados los operadores genéticos como el operador de cruce, el operador de mutación y los métodos de selección; por último, un componente necesario para la aplicación del AG a la optimización con restricciones es cómo manejar las restricciones, porque los operadores genéticos utilizados para manipular los cromosomas a menudo producen descendencia inviable.

9.2.7 Vocabulario del AG

Debido a que el AG tiene sus raíces en la genética natural y en la ciencia de la computación, las terminologías utilizado en las literaturas del AG son una mezcla de lo natural y lo artificial.

En un organismo biológico, se llama un cromosoma a la estructura que codifica la prescripción que especifica cómo el organismo se va a construir. Uno o mas de los cromosomas pueden ser obligados a especificar el organismo completo. El conjunto completo de los cromosomas se llama un genotipo, y el organismo resultante se llama fenotipo. Cada cromosoma comprende un número de estructuras individuales llamadas genes. Cada gen codifica una característica particular del organismo, y la ubicación, o locus, del gen dentro de la estructura de los cromosomas, lo que determina la característica particular que representa al gen. En un trazado particular, un gen puede codificar uno de los varios diferentes valores de la característica particular que representa. Los diferentes valores de un gen se llaman alelos. La correspondencia de términos de los AGs y los términos de optimización se resume en la Tabla nº 9.1

Tabla nº 9.1 Explicación de los términos AG

Algoritmos genéticos	Explicación
Cromosoma (cadena, individuo)	Solución (codificación)
Genes (bits)	Parte de la solución
Locus	Posición del gen
Alelos	Valores del gen
Fenotipo	Solución decodificada
Genotipo	Solución codificada

9.3 Codificación

Una cuestión clave para el AG es cómo codificar una solución de un problema dado en un cromosoma. Este tema ha sido investigado en muchos aspectos, como los caracteres de mapeo desde un espacio genotipo a un espacio fenotipo cuando se decodifican los individuos en soluciones, y las propiedades de metamorfosis cuando se manipulan los individuos por los operadores genéticos

9.3.1 Clasificación de las codificaciones

En la obra de Holland, la codificación se realiza mediante cadenas binarias^[57]. La codificación binaria para los problemas de optimización de funciones se sabe que tiene inconvenientes graves debido a la existencia de los acantilados de Hamming, que describe el fenómeno de que un par de codificaciones con una distancia grande de Hamming, pertenece a los puntos con las distancias mínimas en el espacio fenotipo. Por ejemplo, el par 011111111111 y 1000000000 pertenecen a puntos vecinos en el espacio fenotipo (puntos de la distancia mínima euclidiana) pero tienen la máxima distancia de Hamming en el espacio genotipo. Para cruzar el acantilado de Hamming, todos los bits tiene que ser cambiado a la vez. La probabilidad de que sobre-cruzamiento y la mutación se producirá para cruzar puede ser muy pequeña. En este sentido, el código binario no conserva la localidad de puntos en el espacio fenotipo.

Para muchas aplicaciones del mundo real, es casi imposible de representar sus soluciones con la codificación binaria. Varios métodos de codificación se han creado para problemas particulares con el fin de tener una aplicación efectiva del AG. Según a qué tipo de símbolos se utiliza como los alelos de un gen, los métodos de codificación se pueden clasificar de la siguiente manera:

49. Codificación binaria
50. Codificación número real
51. Entero / codificación de permutación literal
52. Una estructura de codificación de datos generales

La codificación de números reales es el mejor para los problemas de optimización de funciones. Ha sido ampliamente confirmado que la codificación de números reales tiene mayor rendimiento que la codificación binaria o de Gray para optimización de funciones y optimizaciones limitados.

Puesto que la estructura topológica del espacio genotipo para la codificación número real método es idéntica a la del espacio fenotipo, es fácil para nosotros para crear algunos operadores genéticos efectivos de endeudamiento algunas técnicas útiles de lo convencional métodos. El entero o codificación de permutación literal es adecuado para combinatoria problemas de optimización. Dado que la esencia de los problemas de optimización combinatoria es la búsqueda de una mejor permutación o combinación de algunos productos sujetos a alguna limitaciones, la codificación de permutación literal puede ser la manera más razonable para hacer frente a este tipo de cuestiones. Para

más complejos problemas del mundo real, una adecuada estructura de datos se sugiere como el alelo de un gen con el fin de capturar la naturaleza de la problema. En tales casos, un gen puede ser un n-ario o una estructura de datos más complejo.

Según la estructura de codificaciones, los métodos de codificación también se pueden clasificar en los siguientes dos tipos:

- 53. Codificación unidimensional
- 54. Codificación multi-dimensional

En la mayoría de las prácticas, se adoptó el método de codificación unidimensional. Sin embargo, muchos problemas del mundo real tienen soluciones de estructuras multidimensionales. Es natural adoptar un método de codificación multi-dimensional para representar esas soluciones.

Según qué tipo de contenidos se codifican en las codificaciones, la codificación métodos también pueden ser divididos de la siguiente manera:

- 55. Solamente Solución
- 56. Solución + parámetros

En el AG práctico, la primera manera es ampliamente adoptada para concebir una codificación adecuada a un problema dado. La segunda forma en que se utiliza en las estrategias de evolución. Un individuo se compone de dos partes: la primera parte es la solución a un problema dado y la segunda parte, denominada parámetros de la estrategia, contiene varianzas y covarianzas de la distribución normal para la mutación. El propósito para el la incorporación de los parámetros de la estrategia en la representación de los individuos es facilitar la auto-adaptación evolutiva de estos parámetros mediante la aplicación evolutiva de los operadores a ellos. A continuación se realizará la búsqueda en el espacio de soluciones y los parámetros de la estrategia juntos. De esta manera un ajuste y la diversidad adecuada de los parámetros de la mutación deben ser proporcionados en circunstancias arbitrarias.

9.3.2 Inviabilidad y la Ilegalidad

El AG trabaja en dos tipos de espacios como alternativa: el espacio de codificación y e espacio de la solución, o en las otras palabras, el espacio de genotipo y el espacio del fenotipo. Los operadores genéticos trabajan en el espacio, mientras que el genotipo de evaluación y selección de trabajo en el espacio de fenotipo. La selección natural es el vínculo entre los cromosomas y el rendimiento de las soluciones decodificadas. El mapeo del espacio de genotipo al espacio del fenotipo tiene una influencia considerable sobre el desempeño del AG. El problema más importante asociado con el mapeo es que algunos individuos se corresponden a soluciones no factibles a un problema dado. Este problema puede llegar a ser muy severo para problemas de optimización con restricciones y problemas de optimización combinatoria.

Tenemos que distinguir entre dos conceptos básicos: *inviabilidad* y la *ilegalidad*, a menudo son mal utilizados en la literatura. Inviabilidad se refiere al fenómeno de que una solución decodificado de un cromosoma se encuentra fuera de la región factible de un problema dado, mientras que la ilegalidad se refiere al fenómeno de que un cromosoma no representa una solución a un problema dado.

La *inviabilidad* de los cromosomas se origina a partir de la naturaleza de los límites del problema de optimización. Independientemente de los métodos que se utilicen, los algoritmos genéticos o convencional, deben de manejar las restricciones. Para muchos problemas de optimización, la región factible se puede representar como un sistema de igualdades o desigualdades. Por tal casos, los métodos de penalización se pueden utilizar para manejar los cromosomas no factibles. En problemas de optimización restringida, el óptimo se produce normalmente en el límite entre áreas factibles y no factibles. El enfoque penalizador obligará a la genética a buscar para acercarse a la solución óptima en ambos lados de las regiones factibles y no factibles. La ilegalidad de los cromosomas se origina a partir de la naturaleza de las técnicas de codificación.

9.3.3 Propiedades de las codificaciones

Teniendo en cuenta un nuevo método de codificación, por lo general es necesario examinar si podemos construir una búsqueda genética efectiva con la codificación. Varios principios han sido propuesto para evaluar una codificación:

Propiedad 1 (Espacio): Los cromosomas no deberían requerir cantidades extravagantes de la memoria.

Propiedad 2 (Tiempo): La complejidad del momento de ejecutar la evaluación, la recombinación y la mutación en los cromosomas no debería ser de un orden superior.

Propiedad 3 (Viabilidad): Un cromosoma corresponde a una solución factible.

Propiedad 4 (Legalidad): Cualquier permutación de un cromosoma corresponde a una solución.

Propiedad 5 (Integridad): Cualquier solución tiene un cromosoma correspondiente.

Propiedad 6 (Singularidad): El mapeo de cromosomas a las soluciones (decodificación) puede pertenecer a uno de los siguientes tres casos: mapeo 1-a-1, mapeo n-a-1 y mapeo 1-a-n. El mapeo de 1-a-1 es el mejor de los tres; casos y 1-a-n de mapeo es el más inferior.

Propiedad 7 (Heredabilidad): La descendencia de cruce sencillo (es decir, el punto de cruce de un corte) debe corresponder a las soluciones que combinan la característica básica de sus padres.

Propiedad 8 (Localidad): Un pequeño cambio en el cromosoma debería implicar un cambio pequeño en su solución correspondiente.

9.3.4 Inicialización

En general, hay dos maneras de generar la población inicial, es decir, la inicialización heurística y la inicialización al azar, al tiempo que satisface los límites y/o el sistema de restricciones al problema. Aunque la aptitud media de la inicialización heurística es relativamente alta para que pueda ayudar al AG para encontrar soluciones más rápidamente, en la mayoría de problemas a gran escala, por ejemplo, los problemas de diseño de red, el enfoque heurístico es posible que sólo explore una pequeña parte del espacio de soluciones y es difícil encontrar a un nivel óptima general soluciones debido a la falta de diversidad en la población. Por lo general, tenemos que diseñar un procedimiento de codificación en función del cromosoma para generar la población inicial.

9.3.5 Evaluación de la aptitud

La evaluación de la aptitud es comprobar el valor de la solución de la función objetivo sujeta a las restricciones del problema. En general, la función objetivo proporciona el mecanismo para la evaluación de cada individuo. Sin embargo, su rango de valores varía de problema a problema. Para mantener la uniformidad en varios dominios de problemas, podemos utilizar la función de aptitud para normalizar la función objetivo a un rango de 0 a 1. El valor normalizado de la función objetivo es la aptitud del individuo, y el mecanismo de selección se utiliza para evaluar los individuos de la población.

Cuando la búsqueda del AG procede, la población sufre la evolución con la aptitud, formando así una población nueva. En ese momento, en cada generación, las relativamente buenas soluciones se reproducen y las soluciones relativamente malas mueren con el fin de que la descendencia compuesta por las buenas soluciones se reproduzca. Para distinguir entre el soluciones, una función de evaluación (también llamada función de aptitud) desempeña un importante papel en el trono, y el escalado de los mecanismos también es necesario para ser aplicado en la función objetivo para las funciones de aptitud. Al evaluar la función de aptitud de algunos cromosomas, tenemos que diseñar un procedimiento de decodificación dependiendo del cromosoma.

9.4 Los operadores genéticos

Cuando procede el AG, tanto la dirección de la búsqueda de la solución óptima como la velocidad de búsqueda se deben considerar como factores importantes, con el fin de mantener un equilibrio entre la exploración y la explotación en el espacio de búsqueda. En general, la explotación de la información acumulada resultante del AG de búsqueda, se realiza por el mecanismo de selección, mientras que la exploración de nuevas regiones del espacio de búsqueda se explica por los operadores genéticos.

Los operadores genéticos imitan el proceso de la herencia de los genes para crear nuevas crías en cada generación. Los operadores se utilizan para alterar la composición genética de los individuos durante la representación. En esencia, los operadores realizan una búsqueda al azar, y no se puede garantizar que produzcan una descendencia mejorada. Hay tres operadores genéticos comunes: cruce, mutación y selección.

9.4.1 Cruce

Cruce es el operador genético principal. Funciona con dos cromosomas a la vez y genera descendencia mediante la combinación de características entre ambos cromosomas. Una forma sencilla para lograr el cruce sería elegir un punto de corte al azar y generar la descendencia combinando el segmento de uno de los padres a la izquierda del punto de corte con la segmento del otro padre a la derecha del punto de corte. Este método funciona bien con la representación de cadena de bits. El rendimiento del AG depende, en gran medida, de el rendimiento del operador de cruce utilizado.

La *probabilidad de cruce* (denotado por p_c) se define como la probabilidad del número de descendientes producidos en cada generación con el tamaño de la población (por lo general denotado por **popSize**). Esta probabilidad controla el número p_c esperado \times **popSize** de los cromosomas sometidos a la operación de cruce. Una mayor probabilidad de cruce permite la exploración mayor del espacio de soluciones, y reduce las posibilidades de resolverse en un falso óptimo; pero si esta probabilidad es demasiado alta, el resultado es el desperdicio de una gran cantidad de tiempo de computación en la exploración de regiones poco prometedoras del espacio de soluciones.

Hasta ahora, se han propuesto varios operadores de cruce para los números reales codificados, que a grandes rasgos se puede poner en cuatro clases: convencional, aritméticas, basada en la dirección y estocástico.

Los operadores convencionales se obtienen por la ampliación de los operadores para la representación binaria en el caso de codificación real. Los operadores de cruce convencionales pueden ser ampliamente divididos por dos tipos de cruce:

- Cruce sencillo: un punto de corte, corte de dos puntos, punto multi-corte o uniforme
- Cruce aleatorio: cruce plano, cruce mezcla

Los operadores aritméticos se construyen tomando prestado el concepto de combinación lineal de los vectores desde el área de la teoría de conjuntos convexos. La representación genética opera en la coma flotante, los operadores de cruce aritméticos, tales como convexos, afines, lineales, promedios, intermedios, intermedios de cruce extendido, son los que se adoptan normalmente.

Los operadores basados en la dirección se forman mediante la introducción del gradiente aproximado de la dirección en operadores genéticos. El operador de cruce basado en la dirección usa el valor de la función objetivo en la determinación de la dirección de la búsqueda genética.

Los operadores estocásticos dan descendencia por alteración de los padres mediante números aleatorios con alguna distribución.

9.4.2 Mutación

La mutación es un operador de fondo que produce cambios aleatorios espontáneos en varios cromosomas. Una manera sencilla de lograr la mutación sería alterar uno o más genes. En el AG, la mutación sirve para el papel crucial de (a) la sustitución de los genes perdidos de la población durante el proceso de selección para que puedan ser juzgados en un nuevo contexto o (b) la provisión de los genes que no estaban presentes en la población inicial.

La probabilidad de mutación (denotado por p_M) se define como el porcentaje del número total de genes en la población. La probabilidad de mutación controla la capacidad con la que los nuevos genes se introducen en la población para la elección. Si es demasiado baja, muchos genes que habrían sido útiles no se ponen a prueba, mientras que si es demasiado alta, habrá mucha perturbación aleatoria, la descendencia comenzará a perder su semejanza a los padres, y el algoritmo va a perder la capacidad de aprender de la historia de la búsqueda. Hasta ahora, se han propuesto varios operadores de mutación para la codificación de los números reales, que a grandes rasgos se pueden poner en cuatro clases como cruce que puede ser clasificados.

Los operadores de mutación al azar como la mutación uniforme, la mutación de límites, y la mutación plana, pertenecen a los operadores de mutación convencionales, que simplemente reemplazan un gen con un número real seleccionado al azar con un rango especificado. La mutación dinámica (mutación no uniforme) está diseñada para capacidades de ajuste destinadas al logro de la alta precisión, que se clasifica como el operador de mutación aritmética.

El operador de mutación direccional es un tipo de mutación basado en la dirección, que utiliza la expansión del gradiente de la función objetivo. La dirección se puede dar de forma aleatoria como dirección libre para evitar los cromosomas de interferencia en una esquina. Si el cromosoma está cerca de la frontera, la dirección de mutación dada por algunos criterios podría apuntar hacia la cercana frontera y, a continuación podría ocurrir, el bloqueo. Se han propuesto varios operadores de mutación para la codificación de número entero.

- Mutación de **inversión** selecciona dos posiciones dentro de un cromosoma de forma aleatoria y entonces invierte la subcadena entre estas dos posiciones.

- Mutación de **inserción** selecciona un gen al azar y lo inserta en una posición aleatoria.
- Mutación de **desplazamiento** selecciona una subcadena de genes al azar y lo inserta en una posición aleatoria. Por lo tanto, la inserción puede ser visto como un caso especial de desplazamiento.
- Mutación de **intercambio recíproco** selecciona dos posiciones aleatorias y luego intercambia los genes en las posiciones.

9.4.3 Selección

Selección proporciona la fuerza motriz de un AG. Con demasiada fuerza, una búsqueda genética será más lento de lo necesario. Típicamente, una presión de selección inferior se indica en la parte inicio de una búsqueda genética en favor de una amplia exploración del espacio de búsqueda, mientras que una Se recomienda una mayor presión de selección al final de reducir el espacio de búsqueda. Los selección dirige la búsqueda genética hacia regiones prometedoras en el espacio de búsqueda.

Durante las últimas dos décadas, se han propuesto muchos métodos de selección, examinados, y comparación. Los métodos de selección común son los siguientes:

- Selección de la rueda de la ruleta
- $(\mu + \lambda)$ -selección
- Selección de torneo
- La selección de truncamiento
- Selección elitista
- Clasificación y escalado
- Compartir

La **selección de la rueda de la ruleta**, propuesto por Holland, es el tipo de selección más conocido.

La idea básica es determinar la probabilidad de selección o probabilidad de supervivencia para cada cromosoma proporcional al valor de la aptitud. A continuación, un modelo de rueda de la ruleta puede presentar estas probabilidades. El proceso de selección se basa en rodar la rueda el número de veces igual al tamaño de la población, cada vez seleccionando un solo cromosoma para el nuevo procedimiento.

En contraste con la selección proporcional, $(\mu + \lambda)$ La selección determinista son procedimientos que seleccionan los mejores cromosomas de los padres y los hijos. Ambos métodos prohíben la selección de los cromosomas duplicados de la población. Muchos investigadores prefieren utilizar este método para hacer frente a un problema de optimización combinatoria.

La **selección del torneo** genera un torneo, entre unos pocos individuos escogidos aleatoriamente de la población y selecciona el ganador (el que tiene la mejor condición física).

La presión de selección se puede ajustar fácilmente cambiando el tamaño torneo. Si el tamaño torneo es más grande, los individuos débiles tienen menos posibilidades de ser seleccionados.

La selección de **truncamiento** es también un procedimiento determinista que clasifica a todas las personas de acuerdo a su condición física y selecciona a los mejores como padres. La selección elitista es utilizada generalmente como complementaria al proceso de selección proporcional.

Se proponen los mecanismos de clasificación y de escala para mitigar estos problemas. El método de escalamiento mapea los valores de la función objetivo, prima a los valores reales positivos, y la probabilidad de supervivencia para cada cromosoma se determina de acuerdo con estos valores. La aptitud de escalado tiene un doble propósito: (1) para mantener un diferencial razonable entre las calificaciones de la aptitud relativa de cromosomas, y (2) para evitar una toma de control demasiado rápida por parte de algunos super-cromosomas para cumplir con el requisito de limitar la competencia temprano, pero para estimular más tarde.

La selección compartida se utiliza para mantener la diversidad de la población para la optimización de la función multi-modelo. Una optimización de la función de uso compartido se utiliza para mantener la diversidad de la población. Una función compartida es una forma de determinar la degradación de la aptitud de un individuo debido a un vecino, a cierta distancia. Con la degradación, la probabilidad de reproducción de los individuos en un pico público está restringida, mientras que se anima a otros individuos para dar descendencia.

9.5 Restricciones de manipulación

Un componente necesario para la aplicación del AG en la optimización con restricciones es cómo tratar las restricciones para que los operadores genéticos usados para manipular los cromosomas a menudo producen descendencia inviable. Hay varias técnicas propuestas para manejar las limitaciones con el AG. Michalewicz dio una muy buena relación de este problema. Las técnicas existentes se pueden dividir como sigue:

- Estrategia de Rechazo
- Estrategia de Reparación
- Modificación de la estrategia de los operadores genéticos
- Estrategia de penalización

Cada una de estas estrategias tienen ventajas y desventajas.

9.5.1 Estrategia de Rechazo

La estrategia del rechazo descarta todos los cromosomas no factibles creados a lo largo de un proceso evolutivo. Esta es una opción popular en muchos AG. El método puede funcionar razonablemente bien cuando el espacio de búsqueda factible es convexa y constituye una razonable parte de todo el espacio de búsqueda. Sin embargo, este enfoque tiene serias limitaciones.

Por ejemplo, para muchos problemas de optimización con restricciones, donde la población inicial consta de cromosomas no factibles solamente, puede ser que sea esencial para mejorarlos.

Además, muy a menudo el sistema puede alcanzar el óptimo más fácil si es posible "el cruce" en una región factible (especialmente en posibles espacios de búsqueda no-convexos).

9.5.2 Estrategia de Reparación

La reparación de un cromosomas significa que se toma un cromosoma inviable y se genera uno útil a través de algún procedimiento de reparación. Para muchos problemas de optimización combinatoria, es relativamente fácil crear un procedimiento de reparación.

La *estrategia de reparación* depende de la existencia de un procedimiento de reparación determinista a la conversión de una descendencia inviable en un ejecutable. La debilidad del método está en su dependencia del problema. Para cada problema debe ser diseñado en particular, un algoritmo de reparación específica. Además, para algunos problemas, el proceso de reparación de los cromosomas no factibles puede ser tan complejo como resolver el problema original.

El cromosoma reparado se puede utilizar ya sea para la evaluación solamente, o puede reemplazar el original en la población. Liepins tomó el enfoque no reemplazar, es decir, la versión reparada no se devuelve a la población; mientras Nakano y Yamada tomó el enfoque siempre de la sustitución. Orvosh y Davis informaron de una así llamada Regla del 5%: esta regla heurística afirma que en muchos problemas de optimización combinatoria, el AG con un procedimiento de reparación proporcionan el mejor resultado cuando 5% de cromosomas reparados reemplazan a sus originales no factibles. Michalewicz reporta que la regla de sustitución del 15% es un claro ganador para la optimización numérica

9.5.3 Estrategia de los operadores de modificación genética

Un enfoque razonable para hacer frente a la cuestión de la viabilidad es inventar una representación específica del problema y a los operadores genéticos especializados para mantener la viabilidad de los cromosomas. Michalewicz señaló que a menudo este tipo de sistemas son mucho más fiables que cualquier otro algoritmos genéticos basados en el enfoque de castigo. Esta es una tendencia muy popular: muchos médicos

utilizan la representación específica del problema y especializada en la construcción de los operadores de los algoritmos genéticos de gran éxito en muchas áreas. Sin embargo, la búsqueda genética de este enfoque está confinado dentro de una región factible.

9.5.4 Estrategia penalizante

Estas estrategias anteriormente citadas tienen la ventaja de que nunca generan soluciones no factibles pero tienen la desventaja de que consideran que no hay puntos fuera de las regiones factibles. Para el problema altamente restringido, la solución inviable puede tomar una parte relativamente grande de la población. En tal caso, las soluciones factibles pueden ser difíciles de encontrar si sólo nos limitamos a búsqueda genética dentro de las regiones factibles. Glover y Greenberg han sugerido que las técnicas de gestión de restricción que permiten el movimiento a través de regiones inviable del espacio de búsqueda tienden a producir optimización más rápida y producen mejores soluciones finales que la que hacen enfoques para limitar las trayectorias de búsqueda sólo a regiones factibles del espacio de búsqueda. La estrategia de la penalización es un tipo de tales técnicas propuestas para considerar soluciones no factibles en una búsqueda genética.

9.6 Algoritmos genéticos híbridos

Los AG han demostrado ser un enfoque versátil y eficaz para la solución de los problemas de optimización. Sin embargo, hay muchas situaciones en las que el AG no lo realiza particularmente bien, y se han propuesto diversos métodos de hibridación. Uno de las formas comunes de la mayoría de algoritmos genéticos híbridos (HAG) es incorporar la optimización local como un complemento adicional para el bucle canónico del AG de recombinación y selección. Con el enfoque híbrido, la optimización local se aplica a cada descendencia recién generada para moverlo a un óptimo local antes de inyectarlo en la población. El AG se utiliza para realizar la exploración global entre una población mientras se utilizan métodos heurísticos para realizar la explotación local alrededor de los cromosomas. Porque de las propiedades complementarias del AG y las propiedades heurísticas, el enfoque híbrido a menudo supera a cualquiera de los métodos que convencionales, operando solo. Otra forma común es el incorporar parámetros al AG de adaptación. Los comportamientos del AG se caracterizan por el equilibrio entre la de explotación y de exploración en el espacio de búsqueda. El balance está fuertemente afectado por los parámetros de la estrategia como el tamaño de la población, máxima generación, probabilidad de cruce, y la probabilidad de mutación. ¿Cómo elegir un valor para cada uno de los parámetros y cómo encontrar los valores eficientemente son muy importante y prometedoras áreas de investigación en el AG.

9.6.1 Búsqueda genética local

La idea de combinar el AG y la búsqueda heurística local para resolver problemas de optimización ha sido ampliamente investigada y han sido propuestos diversos métodos de hibridación. Hay dos formas comunes de búsqueda local genética: Una

caracterizada por la evolución Lamarckiana y la otra por el efecto Baldwin. Ambos enfoques utilizan la metáfora, de que un individuo aprende (hillclimbs) durante su vida útil (generación).

En el caso de Lamarck, el individuo resultante (después del hillclimbing) se pone de nuevo en la población. En el caso baldwiniano, solamente se cambia la condición física y el genotipo permanece sin cambios. De acuerdo a las experiencias de Whitley, Gordon y Mathias en algunos problemas de prueba, la estrategia de búsqueda baldwiniana a veces puede converger a un óptimo global, cuando la estrategia lamarckiana converge a un óptimo local utilizando la misma forma de búsqueda local. Sin embargo, en todos los casos examinados, la estrategia baldwiniana es mucho más lenta que la estrategia de Lamarck.

Las primeras obras que relacionaban la teoría de la evolución genética y la lamarquiana incluída la propuesta por Grefenstette⁵⁸ que introdujo los operadores lamarquianos en el AG, la de Davidor quien definía la probabilidad lamarquiana para las mutaciones con el fin de permitir a un operador de mutación a estar más controlado y para introducir algunas cualidades de un operador de ascenso local, y la de Shaefer que añadió una asignación intermedia entre el espacio del cromosoma y el espacio de la solución en un simple AG, el cual es lamarquiano por su naturaleza.

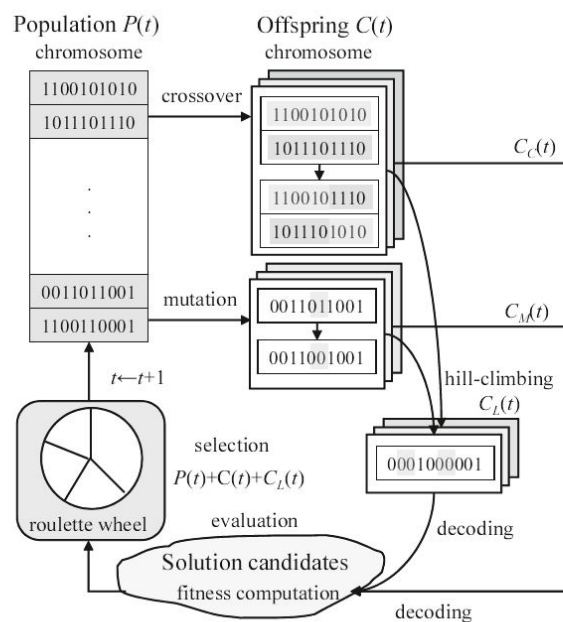


Figura nº 9.3 La estructura general de los algoritmos genéticos híbridos.

Kennedy dio una explicación de AGh con la teoría de la evolución lamarckiana. El simple AG de Holland fue inspirado por la teoría de la selección natural de Darwin. En el siglo XIX, la teoría de Darwin fue desafiada por Lamarck, quien propuso que los cambios ambientales a lo largo de la vida causan cambios estructurales de un organismo que se transmiten a la descendencia. Esta teoría permite a los organismos

pasar a lo largo del conocimiento y de la experiencia que adquieren en su vida. Mientras que ningún biólogo hoy cree que los rasgos adquiridos en el mundo natural se pueden heredar, el poder de la teoría lamarckiana se ilustra por la evolución de nuestra sociedad.

Se transmiten las ideas y el conocimiento de generación en generación, a través de la lengua y la cultura estructurada. El AG, como organismo artificial, puede beneficiarse de las ventajas de la teoría de Lamarck. Al permitir que algunas de las experiencias individuales se transfieran a las personas futuras, mientras podemos mejorar la capacidad del AG para centrarse en las áreas más prometedoras. Después de un enfoque lamarckiano, primero una rutina tradicional de escalada podría utilizar la descendencia como punto de partida y llevar a cabo la optimización rápida y localizada. Después de que se ha aprendido para alcanzar el escenario local, podemos obtener la descendencia a través de la evaluación y de las fases de selección. Un descendiente tiene una oportunidad de transmitir su experiencia a los futuros hijos a través del cruce común.

Sea $P(t)$ y $C(t)$ sea padres e hijos en la generación t actual. el general estructura de HAG se describe como sigue:

Procedimiento nº 2 Algoritmo genético híbrido

```

procedure: hybrid GA
input: problem data, GA parameters
output: the best solution
begin
   $t \leftarrow 0$ ;
  initialize  $P(t)$  by encoding routine;
  evaluate  $P(t)$  by decoding routine;
  while (not terminating condition) do
    create  $C(t)$  from  $P(t)$  by crossover routine;
    create  $C(t)$  from  $P(t)$  by mutation routine;
    climb  $C(t)$  by local search routine;
    evaluate  $C(t)$  by decoding routine;
    select  $P(t+1)$  from  $P(t)$  and  $C(t)$  by selection routine;
     $t \leftarrow t+1$ ;
  end
output the best solution
end

```

En el enfoque híbrido, los organismos artificiales primero pasan a través de la evolución biológica de Darwin y luego pasan a través de la evolución de la inteligencia de Lamarck. La rutina tradicional de ascenso se utiliza como la evolución de Lamarck para tratar de inyectar alguna "inteligencia" en el organismo descendiente antes de volver a ser evaluados.

Moscato y Norman han introducido el término **algoritmo memético** para describir lo que en la búsqueda local juega un papel importante. El término está motivado por la idea de Dawkins de un meme como unidad de información que se reproduce a sí mismo como la gente intercambia ideas. Existe una diferencia fundamental entre los genes y los memes. Antes de que el meme se transmite, típicamente adaptada por la persona que lo transmite como la persona piensa, entiende y procesa el meme, mientras que los genes se pasan en todo. Moscato y Norman vinculados a esta forma de pensar refinamiento local y, por tanto, promovido el término algoritmo memético para describir los algoritmos genéticos que utilizan locales buscar pesadamente. [59]

Procedimiento nº 3 Algoritmo memético

Procedure Memetic Algorithm

Initialize: Generate an initial population;

while Stopping conditions are not satisfied **do**

Evaluate all individuals in the population.

Evolve a new population using stochastic search operators.

Select the subset of individuals, Ω_{ij} , that should undergo the individual improvement procedure.

for each individual in Ω_{ij} **do**

Perform individual learning using meme(s) with frequency or probability of f_{ij} , for a period of t_{ij} .

Proceed with Lamarckian or Baldwinian learning.

end for

end while

Radcliffe y Surry dieron una descripción formal de los algoritmos meméticos, que proporciona un estructura formal homogénea para considerarla memética y de AG. Según a Radcliffe y Surry, si un optimizador local se agrega a un AG y se aplica a todos los sucesores antes de ser insertados en la población, a continuación, un algoritmo memético puede ser considerado simplemente como un tipo especial de búsqueda genética sobre el subespacio de óptimos locales. La recombinación y mutación generalmente producirá soluciones que están fuera de este espacio de óptimos locales, pero un optimizador local, entonces puede reparar este tipo de soluciones a producir hijos finales que se encuentran dentro de este subespacio, produciendo un algoritmo memético como se muestra en la Figura nº 9.4




Figura nº 9.4 La aplicación de una técnica de búsqueda local para un bucle del AG

9.6.2 Parámetro Adaptación

Dado que el AG se inspira en la idea de la evolución, es natural esperar que la adaptación se utiliza no sólo para la búsqueda de soluciones a un problema dado, sino también para la sintonización del AG para el problema particular. Durante los últimos años, muchas técnicas de adaptación se han sugerido y probado con el fin de obtener una aplicación efectiva de los AG con los problemas del mundo real. En general, hay dos tipos de adaptaciones:

- Adaptación a los problemas
- Adaptación a los procesos evolutivos

La diferencia entre estas dos adaptaciones es que la primera defiende la modificación de algunos componentes del AG, como la representación, el cruce, la mutación y la selección, con el fin de elegir una forma adecuada de algoritmo para satisfacer la naturaleza de una problema dado. La segunda sugiere una manera de ajustar los parámetros de la configuraciones del AG, mientras se resuelve el problema. Según Herrera y Lozano, el anterior tipo de adaptación puede ser dividida en las siguientes clases :

- Los ajustes de parámetros de adaptación
- Los operadores genéticos adaptativos
- La selección de adaptación
- La representación de adaptación
- La función de aptitud adaptativa

Entre estas clases, la adaptación de parámetros se ha estudiado extensamente en los últimos quince años, debido a que los parámetros de la estrategia tales como la probabilidad de mutación, cruce probabilidad y tamaño de la población son factores clave en la determinación de la explotación vs. compensación exploración. Los comportamientos del AG se caracterizan por la balanza entre la explotación y exploración en el espacio de búsqueda. El equilibrio está fuertemente afectados por los parámetros de la estrategia como el tamaño de la población, la máxima generación, probabilidad de cruce, y la probabilidad de mutación. ¿Cómo elegir un valor para cada uno de los parámetros y cómo encontrar los valores de manera eficiente, son unas y, muy importantes y prometedoras áreas de investigación del AG.

Por lo general, los parámetros fijos se utilizan en la mayoría de aplicaciones del AG. Los valores para los parámetros se determinaron con un enfoque de conjunto-y-prueba. Desde que el AG es un proceso intrínsecamente dinámico y adaptativo, el uso de parámetros constantes está en contraste con el espíritu evolutivo general. Por lo tanto, es una idea natural intentar modificar los valores de los parámetros de la estrategia durante la ejecución del algoritmo. Es posible hacer esto en varias maneras:

- Mediante el uso de una regla
- Al tomar la información de retroalimentación del estado actual de la búsqueda
- Mediante el empleo de algún mecanismo auto-adaptativo

9.6.3 Clasificación de parámetro Adaptación

Una encuesta reciente sobre técnicas de adaptación se da por Herrera y Lozano, y Hinterding]. De acuerdo con estas clasificaciones de adaptación, hay tres categorías principales.

Adaptación determinista: la adaptación determinista tiene lugar si el valor de un parámetro de estrategia se ve alterado por alguna regla determinista. Por lo general, se utiliza el enfoque de tiempo variable, medido por el número de generaciones. Por ejemplo, la relación de mutación se disminuyó gradualmente a lo largo con el transcurso de la generación usando la siguiente ecuación:

Ecuación nº 9.1

$$p_M = 0,5 - 0,3 \frac{t}{maxGen}$$

donde t es el número de generación actual y $maxGen$ es la generación máxima. Por lo tanto, la relación de mutación se reducirá de 0.5 a 0.2 como el número de generaciones aumentan a $maxGen$

Adaptación de adaptativa : la adaptación adaptativa se lleva a cabo si hay alguna forma de retroalimentación del proceso evolutivo, que se utiliza para determinar la dirección y/o magnitud del cambio en el parámetro de estrategia. Los primeros ejemplos de este tipo de adaptación incluyen "la regla 1/5 de éxito" de Rechenberg en las estrategias de evolución, que se utilizaron para variar el tamaño de paso de mutación. La norma establece que la proporción de mutaciones exitosas a todas las mutaciones debe ser 1/5, por lo tanto, si la relación es mayor que 1/5 se aumenta el tamaño de paso, y si la relación es inferior a 1/5 entonces se disminuye el tamaño del paso. "La aptitud del operador de adaptación" de Davis utiliza la retroalimentación sobre el éxito de un mayor número de operadores de reproducción para ajustar la relación. El mecanismo de adaptación de Julstrom regula la relación entre los cruces y las mutaciones en función de su rendimiento.

Adaptación Auto-adaptativa: la adaptación auto-adaptativa permite parámetros de la estrategia evolucionando, junto con el proceso evolutivo. Los parámetros se codifican en los cromosomas de los individuos y se someten a la mutación y la recombinación. Los parámetros codificados no afectan a la aptitud de los individuos directamente, pero los mejores valores se llevan a las mejores personas y estas personas tendrán más probabilidades de sobrevivir y producir descendencia, por lo tanto, la propagación de los valores de estos mejores parámetros. Los parámetros de libre adaptación pueden ser los que controlen el funcionamiento de los algoritmos evolutivos, los que controlan la operación de reproducción o a otros operadores, o las probabilidades de empleo de procedimientos alternativos.

Las probabilidades de auto-sintonía de cruce y mutación

Gen y Cheng, en su libro, estudiaron diversos métodos adaptativos utilizando varios métodos de control de lógica difusa (FLC). Subbu sugiere un algoritmo genético de lógica difusa controlada (flcGA), y el flcGA utilizando un desarrollo basado en el conocimiento difuso.

Este esquema es capaz de ajustar los operadores de forma adaptativa de las tasas de cruce y mutación, Song utiliza dos FLCs; uno para la tasa de cruce y el otro para la tasa de mutación. Estos parámetros son considerados como las variables de entrada del AG y también se toman como las variables de salida de la FLC. Para aplicar con éxito un FLC a un AG, la clave es producir series y reglas difusas bien formadas. Recientemente, Cheong y Lai sugieren un esquema de optimización para los conjuntos y para las reglas.

El AG controlado por estos FLC fue más eficiente en términos de velocidad de búsqueda y calidad de la búsqueda de un AG que el mismo AG sin ellos. Yun y Gen proponen un algoritmo genético adaptativo (AGA) utilizando FLC.

Mediante el uso de esta estrategia básica de actualización heurística, puede construir un plan detallado para su implementación. Para el esquema detallado, que utilizan los cambios la aptitud media que se producen en las poblaciones de padres e hijos durante las segundas generaciones continuas de AG: aumenta las tasas de incidencia de pC y pM, si que produce constantemente una mejor descendencia durante las dos generaciones continuas.

Sin embargo, también reduce las tasas de ocurrencia si produce constantemente una descendencia más pobre durante las generaciones. Este esquema se basa en el hecho de que anima a los operadores de buen rendimiento a producir mucho mejor descendencia, al tiempo que reduce la posibilidad del mal desempeño de los operadores para destruir a los individuos potenciales durante un proceso de búsqueda genética.

El autoajuste del tamaño de la población

Variando el tamaño de la población entre dos generaciones sucesivas se afecta sólo al operador de selección del AG. Tomando n_t y n_{t+1} como el tamaño de la población actual y la de la generación posterior, respectivamente. La selección de los individuos pueden ser considerada como un proceso repetitivo de n_{t+1} operaciones de selección, con p_j siendo la probabilidad de selección del j -ésimo individuo. Para la mayoría de los operadores de selección, tales como la selección por aptitud y la selección por torneo proporcional, la selección por reemplazo, la probabilidad p_j de selección se mantiene constante para las operaciones n_{t+1} de selección. El número esperado de copias del individuo j -ésimo después de la selección se puede expresar como

Ecuación nº 9.2

$$c(j, t + 1) = p_j n_{t+1} c(j, t)$$

donde $c(j, t)$ es el número de copias del individuo j -ésimo en la generación t . El número esperado de copias del individuo j -ésimo es directamente proporcional al tamaño de la población de la generación subsiguiente. Por lo tanto, la porción de la población relacionada para el individuo j -ésimo después de la selección se puede expresar como

Ecuación nº 9.3

$$\rho(j, t + 1) = \frac{c(j, t + 1)}{n_{t+1}} = \frac{p_j n_{t+1} c(j, t)}{n_{t+1}} = p_j c(j, t)$$

que es independiente del tamaño de la población de la generación posterior, siempre que la variación del tamaño de la población no sea suficiente para modificar significativamente la probabilidad p_j . Sin embargo, un AG con la disminución de tamaño de la población tiene mayor tamaño de población inicial y el tamaño de la población final más pequeño, en comparación con un tamaño de población constante el AG con el mismo coste de cálculo (es decir, la igualdad de *tamaño promedio* de la población). Esto se espera que sea beneficioso, ya que un tamaño de la población más grande al principio ofrece una mejor señal inicial para el proceso de evolución AG mientras que, una población más pequeña tamaño es adecuada al final de la carrera, donde el AG converge al óptimo.

Con base en investigaciones previas, Koumouis y Katsaras propusieron el AG (stGA) en diente de sierra. Un esquema de tamaño de la población variable combinada con una reinicialización de la población se puede introducir al AG para mejorar su rendimiento aún más. El tamaño significativo de la población n del esquema periódico corresponde al tamaño de la población constante AG con el mismo coste de computación. Por otra parte, el esquema se caracteriza por la amplitud D y el período de variación T . Por lo tanto, en una generación específica $n(t)$, el tamaño de la población se determina como

Ecuación nº 9.4

$$n(t) = \text{int} \left(\bar{n} + D - \frac{2D}{T-1} \left(t - T \cdot \text{int} \left(\frac{t-1}{T} \right) - 1 \right) \right)$$

Koumouis y Katsaras propusieron el stAG utilizando un tamaño poblacional con el siguiente esquema variable presentado en la Figura nº 9.5. en la forma de una función de diente de sierra periódica.




Figura nº 9.5 Esquema de la variación de población de dientes de sierra AG.

Estrategia Auto-sintonía por FLC

El AG ha sido conocido por ofrecer ventajas significativas frente a los métodos convencionales utilizando simultáneamente varios principios de búsqueda y heurísticos. Sin embargo, a pesar de la aplicación exitosa del AG a numerosos problemas de optimización, que no tienen fácil la decisión, si la identificación de la configuración correcta de los parámetros genéticos para el problema es o no eficaz. Estos parámetros genéticos determinan la explotación-exploración trade-off en el espacio de búsqueda. Todos los parámetros genéticos deben tener autoajuste dependiendo de la situación de convergencia de la generación actual. Si la mayoría de los cromosomas de la generación actual permanece en la misma zona del espacio de búsqueda, la explotación debe ser aumentada. Recientemente, Lin y Gen propusieron una nueva estrategia de ajuste automático en la que el control de la lógica difusa (FLC) ha sido adoptado para auto-ajuste del equilibrio entre la explotación y exploración basado en el cambio de la aptitud media de las generaciones actuales y pasadas. Diferente a la estrategia de ajuste automático convencional, este auto-tuning AG (atGA) está basada en los dos componentes siguientes:

- Hay tres operadores genéticos: el cruce (el mismo que con un simple AG), la inmigración (una especie de búsqueda al azar), la mutación heurística (una especie de búsqueda heurística).
- Estrategia de autoajuste convierte las probabilidades de tres operadores genéticos anteriores. (p_C : probabilidad de cruce, p_I : probabilidad de inmigración, p_M : mutación heurística probabilidad; $p_C + p_I + p_M \equiv 1$)

Mutación heurística: Este tipo de búsqueda heurística usa las mismas técnicas con búsqueda local genética, que se discutió anteriormente. Una técnica LS se aplica para generar alguna nueva descendencia de padres seleccionados. Esta mutación heurística puede mover la descendencia a un óptimo local. El número de descendientes depende de la probabilidad de mutación p_M . En otras palabras, la probabilidad de mutación determina el peso de exploración para el espacio de búsqueda.

Operador de Inmigración: Moed propuso un operador que la inmigración, para ciertos tipos de funciones, deja el aumento de exploración mientras se mantiene casi el mismo nivel de explotación para el tamaño de la población dada. Es un ejemplo de una estrategia aleatoria que explora el espacio de búsqueda haciendo caso omiso de la explotación de la regiones prometedoras del espacio de búsqueda.

El algoritmo se modifica para (1) incluye la rutina de inmigración, en cada generación, (2) genera y (3) evalúa los miembros aleatorios del $popsiz \cdot p_i$ y (4) reemplaza el $popsiz \cdot p_i$ de los peores miembros de la población con los miembros aleatorios $popsiz \cdot p_i$ (p_i , es la llamada probabilidad de inmigración).

Las probabilidades de inmigración y cruce determinan el peso de la explotación para el espacio de búsqueda. El esquema principal es utilizar dos FLC: auto-tuning para exploración y explotación $T[p_M \wedge (p_C \vee p_I)]$ y el auto-tuning para la explotación genética y la explotación al azar $T[(p_C \vee p_I)]$ se implementan de forma independiente para regular de forma adaptativa los parámetros genéticos durante el proceso de búsqueda genética.

Por el esquema detallado, utilizamos los cambios de la aptitud media que se producen en los padres y las poblaciones descendientes durante generaciones continuas del AG: aumenta la probabilidad de ocurrencia de p_M y disminuye la probabilidad de ocurrencia de p_C y p_I si produce consistentemente mejor descendencia; de lo contrario, disminuye la ocurrencia probabilidad de p_M y aumenta la probabilidad de ocurrencia de p_C y p_I , si produce consistentemente crías más pobres durante las generaciones.

Por ejemplo, en problemas de minimización, podemos establecer el cambio de la aptitud media en la generación t , $\Delta f_{avg}(t)$ como sigue:

Ecuación nº 9.5

$$\Delta f_{avg}(t) = \overline{f_{parSize}}(t) - \overline{f_{offSize}}(t)$$

Ecuación nº 9.6

$$\Delta f_{avg}(t) = \frac{1}{parSize} \sum_{k=1}^{parSize} f_k(t) - \frac{1}{offSize} \sum_{k=1}^{offSize} f_k(t)$$

donde $parSize$ y $offSize$ son el tamaño de las poblaciones padres y descendientes que satisfacen las restricciones, respectivamente. Definimos la regulación de p_M , utilizando los valores de $\Delta f_{avg}(t-i)$, $i = 1, 2, \dots, u$, y definimos p_C y p_I utilizando el coeficiente de correlación de los individuos de la actual generación. Ellos se muestran como sigue:

$$p_M = \text{regulación 1} (\Delta f_{avg}(t-i), i = 1, 2, \dots, u)$$

$$p_C = \text{regulación 2} (\Delta f_{avg}(t-i), i = 1, 2, \dots, u)$$

$$p_I = 1 - (p_M + p_C)$$

donde las rutinas de la "**regulación 1**" y "**regulación 2**" se muestran en el Procedimiento nº 5 y en el Procedimiento nº 6; la función de pertenencia para p_M y p_C se muestra en la **Error! Reference source not found.**; Δf y μ_M, μ_C son

Ecuación nº 9.7

$$\Delta f = \sum_{i=1}^u 2^{t-1} \cdot \lambda(\Delta f_{avg}(t-i)), t \geq u$$

Ecuación nº 9.8

$$\mu_M = \frac{0,8 - 0,2}{2^u - 2\alpha}, \quad 0 \leq \alpha \leq \frac{2^u}{4}$$

Ecuación nº 9.9

$$\mu_C = \frac{0,8(1 - p_M) - 0,1}{2^u - 2\alpha}, \quad 0 \leq \alpha \leq \frac{2^u}{4}$$

Ecuación nº 9.10

$$\lambda(x) = \begin{cases} 1, & \text{si } x \geq 0 \\ 0 & \text{en otro caso} \end{cases}$$

Sea $P(t)$ y $C(t)$ los padres e hijos en la generación t actual, respectivamente. La estructura general del AG de ajuste automático se describe como sigue:

Procedimiento nº 4 Pseudocódigo de la regulación para la regulación auto sintonía GA

procedure: auto-tuning GA

input: problem data, GA parameters

output: the best solution

begin

$t \leftarrow 0$;

initialize $P(t)$ by encoding routine;

evaluate $P(t)$ by decoding routine;

while (not terminating condition) do

 create $C(t)$ from $P(t)$ by crossover routine;

 create $C(t)$ from $P(t)$ by mutation routine;

 create $C(t)$ from $P(t)$ by immigration routine;

 evaluate $C(t)$ by decoding routine;

```

if  $t > u$  then
    auto-tuning  $p_M, p_C$  and  $p_I$  by FLC;
    select  $P(t+1)$  from  $P(t)$  and  $C(t)$  by selection routine;
     $t \leftarrow t+1$ ;
end
output the best solution
end
    
```

Procedimiento nº 5 Pseudocódigo de la regulación para p_M

```

procedure: Regulation 1 for  $p_M$ 
begin
    if  $\Delta f \leq \alpha$  then
         $p_M = 0,2$ 
        if  $\alpha \leq \Delta f \leq 2^u - \alpha$  then
             $p_M = 0,2 + \mu_M \cdot (\Delta f - \alpha)$ 
        if  $\Delta f \geq 2^u$  then
             $p_M = 0,8$ 
    end
end
    
```

Procedimiento nº 6 Pseudocódigo de la regulación para p_C

```

procedure: Regulation 2 for  $p_C$ 
begin
    if  $\Delta f \leq \alpha$  then
         $p_C = 0,8$ 
        if  $\alpha \leq \Delta f \leq 2^u - \alpha$  then
             $p_C = 0,8(1 - p_M) - 0,1 - \mu_C \cdot (\Delta f - \alpha)$ 
        if  $\Delta f \geq 2^u - \alpha$  then
             $p_C = 0,1$ 
    end
end
    
```





Figura nº 9.6 Función de pertenencia para p_M (izq.) y para p_C (der.).

9.7 Algoritmos Genéticos con multi-objetivo

Las ofertas de optimización con los problemas de la búsqueda de soluciones a través de una serie de posibles opciones para optimizar ciertos criterios suelen ser múltiples. Si sólo hay un criterio para ser tomado en consideración, se convierten en problemas de optimización de objetivos individuales, que han sido ampliamente estudiados durante los últimos 50 años. Si hay más de un criterio que deben ser tratados al mismo tiempo, tenemos varios problemas de optimización objetivos. Problemas objetivos múltiples surgen en el diseño, modelado y planificación de muchos sistemas reales complejos en las áreas de la producción industrial, el transporte urbano, presupuesto de inversión de capital, la gestión forestal, la gestión de embalses, la disposición y paisajismo de nuevas ciudades, la distribución de energía, etc. Es fácil ver que casi todos importante problema de decisión del mundo real implica múltiples y contradictorios objetivos que deben ser abordados en el respeto de diversas limitaciones, llevando a abrumadora complejidad del problema. Los múltiples problemas de optimización objetivos tienen estado recibiendo cada vez mayor interés por parte de los investigadores con diversos antecedentes ya principios de 1960. Hay una serie de estudiosos que han hecho contribuciones significativas al problema. Entre ellos, el de Pareto es quizás uno de los más reconocidos pioneros en el campo. Recientemente, el AG ha recibido considerable atención como un enfoque novedoso para problemas de optimización multiobjetivo, resultando en un conjunto de investigaciones y aplicaciones conocido como optimización multiobjetivo evolutiva (OME).

9.8 Conceptos básicos de optimizaciones multiobjetivo

Un único problema de optimización objetivo general se da en la siguiente forma:

Ecuación nº 9.11

$$\begin{aligned} \max z &= f(\mathbf{x}) \\ \text{s. t. } g_i(\mathbf{x}) &\leq 0, i = 1, 2, \dots, m \\ x &\geq 0 \end{aligned}$$

donde $x \in R^n$ es un vector de n variables de decisión, $f(\mathbf{x})$ es la función objetivo, y $g_i(\mathbf{x})$ son funciones m de restricción de desigualdad, que forman el área de soluciones factibles. Por lo general, denotamos la zona factible en el margen de decisión con el conjunto S de la siguiente manera:

Ecuación nº 9.12

$$S = \{x \in R^n \mid g_i(x) \leq 0, i = 1, 2, \dots, m, x \geq 0\}$$

Sin pérdida de generalidad, un problema de optimización objetivo múltiple puede ser formalmente representado como sigue:

Ecuación nº 9.13

$$\begin{aligned} & \max \{z_1 = f_1(x), z_2 = f_2(x), \dots, z_q = f_q(x)\} \\ & \text{s. t. } g_i(x) \leq 0, i = 1, 2, \dots, m \\ & x \geq 0 \end{aligned}$$

A veces el grafo del problema objetivo múltiple es tanto espacio de decisión como espacio de criterio. S se utiliza para denotar la región factible en el espacio de decisión y Z es usado para denotar la región factible en el espacio criterio

Ecuación nº 9.14

$$Z = \{z \in R^q \mid z_1 = f_1(x), z_2 = f_2(x), \dots, z_q = f_q(x), x \in S\}$$

donde $z \in R^q$ es un vector de valores de funciones objetivo q . En las otras palabras, Z es el conjunto de imágenes de todos los puntos en S . Aunque S está confinado al ortante no negativo de R^n , Z no está confinado necesariamente al ortante no negativo de R^q .

9.8.1 Soluciones no dominadas

En principio, los múltiples problemas de optimización objetivos son muy diferentes de los problemas de la optimización de un solo objetivo. Para el caso de único objetivo, se intenta obtener la mejor solución, que es absolutamente superior a todas las otras alternativas. en el caso de múltiples objetivos, no tiene por qué existir tal solución que sea lo mejor con respecto a todos los objetivos debido a la inconmensurabilidad y el conflicto entre los objetivos. Una solución puede ser el mejor con un único objetivo, pero peor en otros objetivos.

Por lo tanto, generalmente existe un conjunto de soluciones para el caso de objetivo múltiple que no se puede simplemente compararse con los demás. Tales tipos de soluciones son llamadas soluciones no dominadas o soluciones óptimas de Pareto, para los que no mejorar en cualquier función objetivo es posible sin sacrificar al menos una de las otras funciones objetivo. Para un punto dado en el espacio criterio Z no dominado, su punto de imagen en el espacio de decisión S se llama eficientes o no inferior. Un punto en S es eficiente si y sólo si su imagen en Z están no dominados. El concepto de Pareto soluciones óptimas y soluciones dominadas se muestra en la Figura nº 9.7




Figura nº 9.7 El concepto de soluciones óptimas de Pareto (caso de maximización)

Definición 1.1. Para que un punto dado $z^0 \in Z$, sea no dominado si y sólo si no existe otro punto tal que $z \in Z$, para el caso de maximización,

Ecuación nº 9.15

$$z_k > z_k^0, \text{ para algunos } k \in \{1, 2, \dots, q\} \text{ y}$$

$$z_k \geq z_k^0, \text{ para todos } l \neq k$$

donde, z^0 es un punto dominado en el criterio espacial Z .

Definición 1.2. Para un punto dado $z^0 \in S$, es eficiente si y sólo si, no existe otro punto $x \in S$ tal que, para el caso de maximización,

Ecuación nº 9.16

$$f_k(x) > f_k(x^0), \text{ para algunos } k \in \{1, 2, \dots, q\} \text{ y}$$

$$f_l(x) \geq f_l(x^0), \text{ para todos } l \neq k$$

donde x^0 es ineficiente.

Un punto en el espacio de decisión es eficiente si y sólo si, su imagen es un punto no dominado con el criterio espacial Z . Para ilustrar las definiciones anteriores, se considera la siguiente programación lineal problema:

Ecuación nº 9.17

$$\begin{aligned} \text{máx } f_1(x_1, x_2) &= -x_1 + 3 \cdot x_2 \\ \text{máx } f_2(x_1, x_2) &= 3 \cdot x_1 + x_2 \\ \text{s. t. } f_2(x_1, x_2) - f_1(x_1, x_2) - 2 &\leq 0 \\ f_2(x_1, x_2) - 2 \cdot x_1 + x_2 - 2 &\leq 0 \\ x_1, x_2 &\geq 0 \end{aligned}$$

La región factible S en el espacio de decisión se muestra en la Figura n° 9.8. Los puntos extremos de la región factible son $x^1(0,0)$, $x^2(1,0)$, $x^3(2/3,2/3)$, y $x^4(0,1)$. La región factible Z en el criterio espacial se obtiene el mapeo del conjunto S mediante el uso de dos objetivos Ecuación n° 9.17 , como se muestra en la Figura n° 9.8, los correspondiente puntos extremos son $z^1(0,0)$, $z^2(-1,3)$, $z^3(4/3,8/3)$ y $z^4(3,1)$. De las figuras observamos que ambas regiones son convexas y los puntos extremos de Z son las imágenes de los puntos extremos de S .




Figura n° 9.8 Región factible y soluciones eficientes espacio de decisión S y en espacio de criterio Z

En cuanto a los puntos entre z^4 y z^3 , se observa que a medida que $f_2(x_1, x_2)$ aumenta de 1 a $8/3$, $f_1(x_1, x_2)$ disminuye de 3 a $4/3$, y, en consecuencia, todos los puntos entre z^4 y z^3 son puntos no dominados. De la misma manera, todos los puntos entre z^3 y z^2 también son puntos no dominados. Los puntos eficientes correspondientes en la decisión el espacio se encuentran en los segmentos entre el punto x^2 y x^3 , y entre el punto x^3 y x^4 , respectivamente.

Hay un punto especial en el espacio de criterio Z llamado un *punto ideal* (o una solución ideal positiva), denotado por $z^* = (z_1^*, z_2^*, \dots, z_q^*)$ donde $z_k^* = \sup \{f_k(x) \mid x \in S\}$, $k = 1, 2, \dots, q$. El punto z^* se llama un punto ideal, porque por lo general no es alcanzable. Hay que tener en cuenta que, de forma individual, z_k^* puede ser alcanzable. Pero para encontrar un punto z^* que pueda simultáneamente maximizar cada $f_k(\cdot)$, $k = 1, 2, \dots, q$ suele ser muy difícil.

9.8.2 Características y Aplicación del AG multiobjetivo

Las características intrínsecas del AG demuestran por qué la búsqueda genética está, posiblemente, bien adaptada a problemas de optimización de objetivos múltiples. La característica básica del AG es la búsqueda de dirección múltiple y global mediante el mantenimiento de una población de potenciales soluciones de generación en generación. El enfoque *población-a-población* es útil para explorar todas las soluciones de Pareto.

El AG no tiene mucha exigencia matemática con respecto a los problemas y puede manejar cualquier tipo de funciones y limitaciones objetivas. Debido a su evolución natural, el AG puede buscar soluciones sin tener en cuenta específicamente el funcionamiento interior del problema. Por lo tanto, es aplicable a la solución muchos más problemas complejos más allá del alcance de los métodos convencionales interesantes mediante el uso del AG.

Debido a que el AG, es como una especie de meta-heurística, nos proporciona una gran flexibilidad para hibridar con métodos convencionales en su estructura principal, podemos llevar con ventaja tanto del AG y los métodos convencionales para hacer mucho más eficiente las implementaciones para los problemas. La investigación en curso sobre la aplicación del AG a los múltiples problemas de optimización objetivas presenta un formidable campo teórico y el desafío práctico para la comunidad matemática].

Sea $P(t)$ y $C(t)$ sea padres e hijos en la generación t actual. La estructura general del *algoritmo genético multiobjetivo* (moGA) se describe como sigue:

Procedimiento nº 7 Estructura del algoritmo genético multiobjetivo

```

procedure: moGA
: problem data, GA parameters
output: Pareto optimal solutions E
begin
     $t \leftarrow 0$ ;
    initialize  $P(t)$  by encoding routine;
    calculate objectives  $f_i(P)$ ,  $i = 1, \dots, q$  by decoding routine;
    create Pareto  $E(P)$ ;
    evaluate  $eval(P)$  by fitness assignment routine;
    while (not terminating condition) do
        create  $C(t)$  from  $P(t)$  by crossover routine;
        create  $C(t)$  from  $P(t)$  by mutation routine;
        calculate objectives  $f_i(C)$ ,  $i = 1, \dots, q$  by decoding routine;
        update Pareto  $E(P, C)$ ;
        evaluate  $eval(P, C)$  by fitness assignment routine;
        select  $P(t+1)$  from  $P(t)$  and  $C(t)$  by selection routine;
         $t \leftarrow t+1$ ;
    end
output Pareto optimal solutions  $E(P, C)$ 
end

```

9.8.3 Mecanismo de Asignación de Aptitud

El AG es esencialmente un tipo de método de meta-estrategia. Cuando se aplica el AG para resolver un dado problema, es necesario refinar sobre cada uno de los componentes principales del AG, tales como los métodos de codificación, operadores de recombinación, la asignación de la aptitud, la selección operadores, las limitaciones de manipulación, y así sucesivamente, con el fin de obtener una mejor solución para el problema dado. Debido a que los problemas de optimización multiobjetivo son de natural extensiones de problemas de optimización con restricciones y combinatorias, muchos métodos útiles, basados en los AG se han desarrollado durante las últimas dos décadas. Uno de los temas especiales en problemas de optimización multiobjetivo es la asignación de mecanismos de aptitud. Desde la década de 1980, muchos mecanismos de asignación de aptitud se han propuesto y aplicado en problemas de optimización multiobjetivo. Aunque la mayor parte de los mecanismos de asignación de aptitud son sólo diferentes enfoques y adecuados para diferentes los casos de problemas de optimización multiobjetivo, con el fin de comprender el desarrollo de moGA, clasificamos los algoritmos de acuerdo con propuestas de diferentes años enfoques:

Generación 1 **Enfoque Evaluación Vector:**

AG vector evaluado (veGA),

Generación 2 **Clasificación Pareto + Diversidad:**

AG multiobjetivo (moGA),]

AG clasificación no dominado GA (nsGA),

Generación 3 **Suma ponderada + Preservación Elitista:**

AG peso aleatorio(rwGA),

AG peso adaptativo GA (awGa),]

Algoritmo Evolucionario de Pareto Evolutionary II (spEA II),

clasificación no dominada GA II (NSGA II),

peso de adaptación interactivo GA (i-awGa),

9.8.4 Enfoque de la Evaluación por Vector: Generación 1

Algoritmo Genético Vector Evaluado (veGA: Schaffer): veGA es la primer trabajo notable para resolver los problemas multiobjetivo. En lugar de utilizar una medida de la aptitud escalar para evaluar cada cromosoma, se utiliza una medida del vector de la aptitud para crear la próxima generación. En el enfoque de veGa, la etapa de selección en cada generación se convierte en un bucle; cada vez que a través del bucle de la fracción apropiada de la siguiente generación, o subpoblaciones, se seleccionan sobre la base de cada uno de los objetivos. Entonces toda la población se baraja a fondo para aplicar operadores de cruce y de mutación. Esto se realiza para lograr el apareamiento de individuos de diferentes subpoblaciones. Individuos no dominados se identifican mediante el control de la población a medida que evoluciona, pero esta información no es utilizada por el propio veGA. Este enfoque, se ilustra en la Figura nº 9.9 se protege

la supervivencia de los mejores individuos en uno de los objetivos y, al mismo tiempo, se proporcionan las probabilidades apropiadas para la selección múltiple de los individuos que son mejores que la media en más de un objetivo.

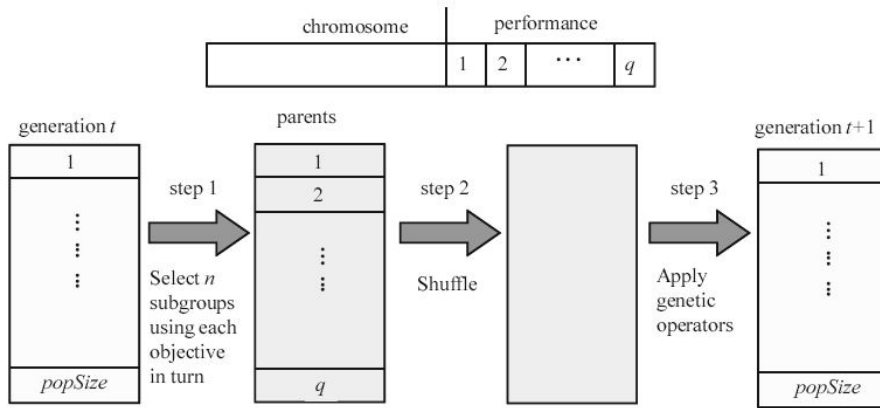


Figura nº 9.9 Ilustración de la selección veGA.

Un sencillo problema de dos objetivos con una variable se utiliza para probar las propiedades del veGA :

Ecuación nº 9.18

$$\begin{aligned} \min f_1(x) &= x^2 \\ \min f_2(x) &= (x - 2)^2 \\ \text{s. t. } x &\in R^1 \end{aligned}$$

La Figura nº 9.10 (a) traza el problema mediante la restricción variable x dentro de la región de -2 a 4 . Está claro que las soluciones de Pareto constituyen todos los valores de x que varían de 0 a 2 . La Figura nº 9.10 (b) representa gráficamente el problema en el criterio de espacio.

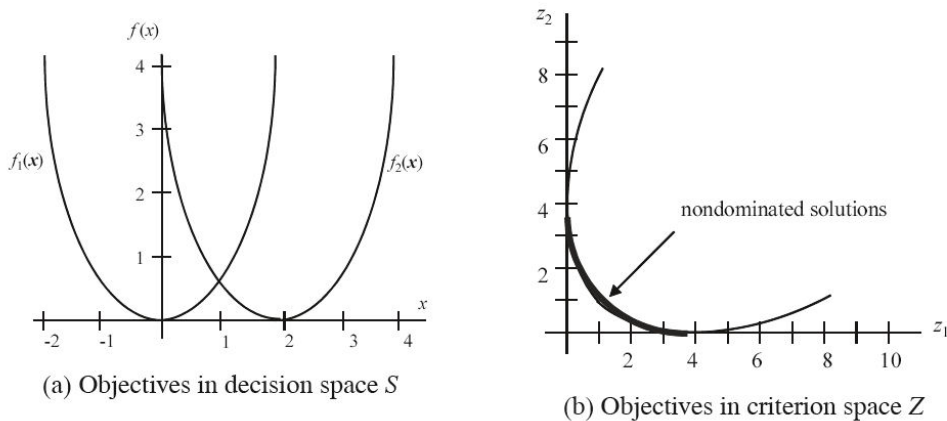


Figura nº 9.10 Objetivos en el espacio de decisión S y el criterio de espacio Z .

Los parámetros de los algoritmos genéticos se establecen como sigue: la máxima generación es de 500, el tamaño de la población es de 100, la longitud de la cadena (código binario) 32, la probabilidad de cruce 1,0, y la probabilidad de mutación 0. El rango inicial para la variable x es $(-10,10)$. Los población inicial se muestra en la Figura nº 9.11 (a). En la generación 10, la población convergieron hacia a la región no dominados como se muestra en la Figura nº 9.11 (b). En la generación 100, casi toda la población cayó en la región de soluciones no dominadas como se muestra en la Figura nº 9.11 (c). Se observa que en la generación 500, la población converge a sólo tres subregiones como se muestra en la Figura nº 9.11 (d). Este es el fenómeno de la especiación.

Las obras de Schaffer se consideran comúnmente como el primer esfuerzo de abrir el dominio de múltiples optimizaciones objetivas a los AGs. A pesar de que el veGA no puede dar una solución satisfactoria al problema de optimización con objetivo múltiple, proporciona algunos consejos útiles para el desarrollo de otras nuevas implementaciones de GA. La mayoría de los trabajos siguientes a menudo se refieren a veGa como paradigma para comparar rendimientos.

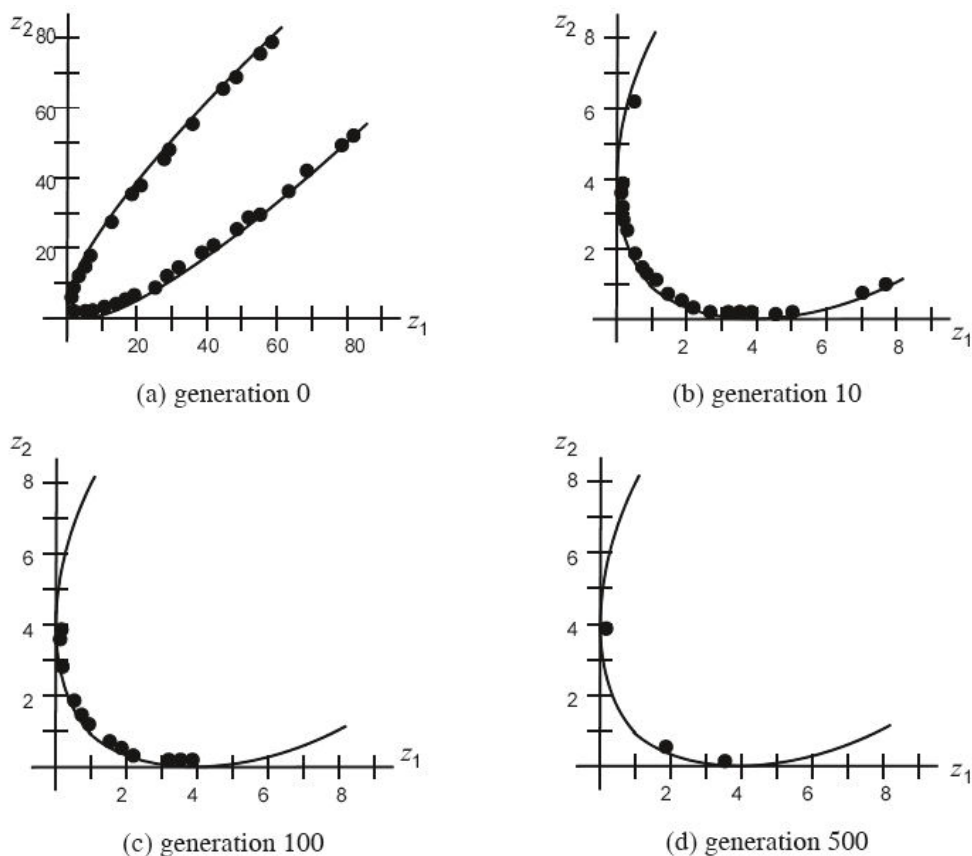


Figura nº 9.11 Población en diferentes generaciones obtenidas utilizando veGa.

9.8.5 Clasificación de Pareto + Diversidad: Generación 2

El rango del método Pareto basado en la asignación de aptitud fue sugerido por primera vez por Goldberg. El procedimiento de clasificación es como sigue: dando el rango 1 a los individuos no dominados y eliminarlos de la contienda, luego encontrar el siguiente grupo de los individuos no dominados y la asignación de rango 2 a ellos. El proceso continúa hasta que toda la población ocupa el puesto. Este enfoque se ilustra en la Figura n° 9.12 para un caso simple con dos objetivos que se minimizan simultáneamente.

Algoritmo Genético multiobjetivo: Fonseca y Fleming propusieron un algoritmo genético multiobjetivo en el que el rango de un cierto individuo se corresponde con el número de individuos en la población actual por el cual está dominado. Con base en este esquema, los individuos no dominados todos se asignan rango 1, mientras que los dominados son penalizados de acuerdo a la densidad de población de la región correspondiente de la superficie compensación. La Figura n° 9.13 ilustrar una caso sencillo con dos objetivos para minimizar simultáneamente.

Algoritmo Genético de clasificación no dominada de Srinivas y Deb también desarrollaron una asignación de aptitud basado el rango-Pareto y que llamaron Algoritmo Genético de clasificación no dominada (nsGA). En su método, las soluciones no dominadas que constituyen un frente no dominado se les asigna el mismo valor de aptitud ficticio.




Figura n° 9.12 Ilustración de la clasificación de Goldberg (caso de minimización).




Figura n° 9.13 Ilustración de clasificación moGA (caso de minimización).

Estas soluciones se comparten con sus valores de aptitud ficticias (compartición fenotípica en los vectores de decisión) y son ignorados en el ulterior proceso de clasificación. Por último, la aptitud ficticia se establece en un valor menor que el valor más pequeño de la aptitud compartido en el frente no dominados actual. Luego se extrae la siguiente frontal. Este procedimiento se repite hasta que se clasifican todos los individuos de la población.




Figura n° 9.14 Ilustración de NSGA rango (caso de minimización)

9.8.6 Suma ponderada + Protección Elitista: Generación 3

Algoritmo Genético-peso aleatorio Ishibuchi y Murata propusieron un método de asignación de aptitud basado en la suma ponderada, llamado Algoritmo Genético de peso aleatorio (rwGA), para obtener una dirección de búsqueda hacia la variable en la frontera de Pareto. El enfoque de suma ponderada puede ser visto como una extensión de los métodos utilizados en el enfoque convencional para las optimizaciones multiobjetivo. Se asignan pesos a cada función objetivo y se combina los objetivos ponderados en una sola función objetivo. Por lo general, hay dos tipos de comportamientos de búsqueda en el espacio objetivo: Búsqueda en dirección fija y búsqueda múltiple de dirección como se demuestra en la Figura n° 9.15. (a). El enfoque de ponderaciones fijas hace que los algoritmos genéticos muestren una tendencia a muestrear el área hacia un punto fijo en el criterio de espacio, mientras que el enfoque de pesos al azar hace que muestren los algoritmos genéticos una tendencia de dirección de búsqueda variable, para ser capaz de tomar muestras de manera uniforme la zona hacia toda la frontera.

En el rwGA, se asigna a cada objetivo $f_k(x)$ un peso $w_k = \frac{r_k}{\sum_{j=1}^q r_j}$, donde r_j es un número aleatorio no negativo entre $[0,1]$ con funciones objetivo q . Y el valor de la aptitud escalar se calcula resumiendo el valor objetivo de la función ponderada $w_k \cdot f_k(x)$. Para buscar soluciones múltiples en paralelo, los pesos no son fijos a fin de permitir la búsqueda genética a la muestra uniformemente desde toda la zona hacia toda la frontera. El procedimiento de rwGA se muestra en la Figura n° 9.15




Figura nº 9.15 Ilustración de búsqueda de dirección fija y múltiple en el espacio criterio (caso de minimización).

Procedimiento nº 8 Pseudocódigo de rwGA

procedure : rwGA

input : El objetivo $f_k(v_i)$ de cada cromosoma v_i , $k = 1, 2, \dots, q \forall i \in popSize$

output: Valor de aptitud $eval(v_i)$, $\forall i \in popSize$

begin

$r_j \leftarrow \text{random}[0, 1], 1, 2, \dots, q; // \text{Número aleatorio no negativo}$

$w_k \leftarrow r_k / \sum_{j=1}^q r_j, k = 1, 2, \dots,$

$eval(v_i) \leftarrow \sum_{j=1}^q w_k (f_k(v_i) - z_k^{min}), \forall i$

output $eval(v_i), \forall i$

end

Algoritmo Evolucionario de Pareto fuerte Se ha propuesto el algoritmo evolucionario de Pareto (spEA) que combina varias características del anterior algoritmo genéticos multiobjetivo (spGA) en una única forma. El procedimiento de asignación de aptitud es un proceso de dos etapas. En primer lugar, se clasifican los individuos en el conjunto no dominado externo P^f . Cada solución $i \in P^f$ es asignado a un valor real $s_i \in [0, 1)$, llamado fuerza; s_i es proporcional al número de miembros de la población $j \in P$ para los cuales $i > j$. Sea n el número de individuos en P que son cubierto por i y asumiendo que N es del tamaño de P . Entonces si se define como $s_i = n / (N + 1)$. Los la aptitud de f_i de un objetivo es igual a su fuerza: $f_i = s_i$. Después, los individuos en la población P son evaluados. Se calcula la aptitud de un individuo $j \in P$ sumando los puntos fuertes de todas las soluciones externas no dominadas $i \in P^f$ que cubre j . $f_j = 1 + \sum_{i \in (i > j)} s_i$ es la mejora, donde $f_j \in [1, N)$. La Figura nº 9.16 muestra una ilustración de spEA para un problema de maximización con dos objetivos.




Figura nº 9.16 Ilustración de spEA (caso de maximización).

Algoritmo genético peso adaptativo (awGa): Gen y Cheng propusieron un enfoque de pesos adaptativos que utiliza alguna información útil de la población actual para reajustar los pesos con el fin de obtener una presión de búsqueda hacia el punto ideal positivo. Para las soluciones examinadas en cada generación, definir dos puntos extremos: la máxima extrema punto z^+ y la mínima extrema señalar z^- en el criterio de espacio mientras que se sigue:

Ecuación nº 9.19

$$z^+ = \{z_1^{max}, z_2^{max}, \dots, z_q^{max}\}$$

$$z^- = \{z_1^{min}, z_2^{min}, \dots, z_q^{min}\}$$

donde z_k^{min} y z_k^{max} son el valor máximo y el valor mínimo para el objetivo k en la población actual. P denota el conjunto de la población actual. Para un individuo dado x , el valor y mínimo al valor máximo para cada objetivo se define como la siguiente:

Ecuación nº 9.20

$$z_k^{max} = \max \{f_k(x) \mid x \in P\}, k = 1, 2, \dots, q$$

$$z_k^{min} = \min \{f_k(x) \mid x \in P\}, k = 1, 2, \dots, q$$

El hiper paralelogramo definido por los dos puntos extremos es un hiper paralelogramo mínimo que contiene todas las soluciones actuales. Los dos puntos extremos son renovados en cada generación. El punto extremo máximo se aproximará gradualmente a la punto ideal positivo. El peso de adaptación para k objetivo se calcula mediante la siguiente ecuación:

Ecuación nº 9.21

$$w_k = \frac{1}{z_k^{max} - z_k^{min}}, \quad k = 1, 2, \dots, q$$

Para una x individual dada, la función objetivo suma ponderada está dada por la siguiente ecuación:

Ecuación nº 9.22

$$z(x) = \sum_{k=1}^q w_k (f_k(x) - z_k^{\min}) = \sum_{k=1}^q \frac{f_k(x) - z_k^{\min}}{z_k^{\max} - z_k^{\min}}$$

Como los puntos extremos se renuevan en cada generación, los pesos se renuevan en consecuencia. La ecuación anterior es un hiperplano definido por la siguiente extrema punto en soluciones actuales:

Se trata de una línea móvil adaptativa definida por los puntos extremos (z_1^{\max}, z_2^{\min}) y (z_1^{\min}, z_2^{\max}) , como se muestra en la Figura nº 9.17 El rectángulo definido por los puntos extremos (z_1^{\max}, z_2^{\min}) y (z_1^{\min}, z_2^{\max}) es el rectángulo mínimo que contiene todas las soluciones actuales.




Figura nº 9.17 Pesos adaptativos y hiperplano adaptativo (caso de maximización)

Como demostración en la Figura nº 9.17, el hiperplano divide el espacio criterios Z en dos espacios: uno la mitad de espacio medio contiene el punto ideal positivo, denotado como Z^+ y la otra mitad contiene el espacio lugar ideal negativo, denominado Z^- . Todas las soluciones de Pareto examinados se encuentran en el espacio Z^+ y todos los puntos que se encuentran en el espacio Z^+ tienen valores de aptitud más grandes que los puntos en espacio Z^- . A medida que el punto extremo máximo se aproxima al punto ideal positivo junto con el progreso evolutivo, el hiperplano se acercará gradualmente al punto ideal positivo. Por lo tanto, el awGa puede reajustar sus pesos de acuerdo con la

población actual con el fin de obtener una presión de búsqueda hacia a la ideal positivo punto. El procedimiento de awGa se muestra en Procedimiento nº 9

Algoritmo genético clasificación no dominada II (nsGA II): Deb sugiere un enfoque basado en la clasificación no dominada, el llamado Algoritmo Genético de clasificación no dominada II (nsGA II), que alivia los tres dificultades: la complejidad computacional, el enfoque no elitista, y la necesidad de especificar un parámetro de intercambio de. El nsGA II se adelantó desde su origen al nsGA. En nsGA II como se muestra en el Procedimiento nº 10, con un enfoque de clasificación de no dominados se utiliza para crear cada individuo en un rango de Pareto, y un método de asignación de la distancia de hacinamiento que se aplica para poner en práctica la estimación de la densidad.

Procedimiento nº 9 Pseudocódigo de awGA

procedure : awGa

input : El objetivo $f_k(v_i)$ de cada cromosoma v_i , $k = 1, 2, \dots, q \forall i \in popSize$

output: Valor de aptitud $eval(v_i)$, $\forall i \in popSize$

begin

$\{z_k^{max} \leftarrow \max \{f_k(v_i)\}, k=1, 2, \dots, q; // z^+ \text{ punto extremo máximo}$

$\{z_k^{min} \leftarrow \min \{f_k(v_i)\}, k=1, 2, \dots, q; // z^+ \text{ punto extremo mínimo}$

$w_k \leftarrow \frac{1}{z_k^{max} - z_k^{min}}, k = 1, 2, \dots, q$

$eval(v_i) \leftarrow \sum_{j=1}^q w_k (f_k(v_i) - z_k^{min}), \forall i$

output

end

Después de calcular la aptitud de cada individuo i por el procedimiento mostrado en el Procedimiento nº 9, el nsGA II adopta un proceso de selección especial. Es decir, entre dos individuos con rango no dominación r_i y r_j , y las distancias de hacinamiento d_i y d_j , que prefieren la solución con el (mejor) rango inferior. De lo contrario seleccionamos el mejor dependiendo de las siguientes condiciones. Y un ejemplo de caso sencillo con dos objetivos que se deben reducir al mínimo el uso de nsGA II se muestra en la Figura nº 9.18

Ecuación nº 9.23

$$i < j \text{ if } (r_i < r_j) \text{ or } ((r_i = r_j) \text{ and } (d_i > d_j))$$

El AG de peso adaptativo interactivo (i-awGa: Lin y Gen): En general, la principal idea del enfoque basado en la clasificación de Pareto es una clasificación clara para cada cromosoma entre la solución no dominada y la solución dominada.

Sin embargo, es difícil aclarar la diferencia entre las soluciones no dominadas (o las soluciones dominadas). Aunque hay diferencias entre el soluciones dominadas (2,2) y

(8,8), pero no hay diferencias claras entre valora su aptitud 13/5 y 05/11 por la algoritmo evolutivo de Pareto.

A diferencia de la asignación de aptitud de la clasificación de Pareto, basada en la suma ponderada de la asignación de aptitud, asigna pesos a cada función objetivo y combina la objetivos ponderados en una sola función objetivo. Es más fácil para calcular el peso de la suma de la aptitud y el proceso de clasificación se hace innecesario; por lo que es efectiva al considerar el tiempo de cálculo para resolver los problemas. Además, otra característica del enfoque de la suma ponderada se utiliza para ajustar la búsqueda genética hacia la frontera de Pareto.

Para combinar los objetivos ponderados en una sola función objetivo, los buenos valores de aptitud se asignan con soluciones cercanas a la frontera de Pareto, los valores de aptitud (12/11, 14/11, 13/11) de la mayoría de las soluciones dominadas ((10, 4), (8,8), (6,9)) son mayores que los valores de aptitud (11/11, 11/11) de algunas soluciones no dominadas ((12,1), (1,12)) mediante el uso del enfoque de asignación de aptitud basado en la adaptación del peso. Ver Figura nº 9.19

Procedimiento nº 10 Pseudocódigo de nsGa II

Procedure nsGa II

input El objetivo $f_k(v_i)$ de cada cromosoma v_i , $k = 1, 2, \dots, q \forall i \in popSize$

output Valor de aptitud $eval(v_i)$, $\forall i \in popSize$

begin

set $P \leftarrow \{v_i\}$; ordenación no dominada (r)

$rank \leftarrow 1$;

while do $P \neq \emptyset$ **do**

for $i=1$ to $popSize$

if v_i es solución no dominada **then**;

1 $\leftarrow rank$;

$P \leftarrow P \setminus \{v_i | r_i = rank\}$;

$rank \leftarrow rank+1$

$r_i \leftarrow 0$, $\forall i \in popSize$ // distancia a la asignación

for $k = 1$ to q

$\{j\} \leftarrow \text{sort}\{P\} \max\{z_k^j\}$, $\forall i \in P$

$d_k^1 = d_k^{popSize} \leftarrow \infty$

$d_k^1 \leftarrow \frac{d_k^{j+1} - d_k^{j-1}}{\max\{z_k^j\} - \min\{z_k^j\}}$, $j = 2, \dots, popSize - 1$

$d_i = \sum_{k=1}^q d_k^j$, $\forall i \in popSize$;

output $eval(v_i) = \{r_i, d_i\}$, $\forall i$

end

Lin y Gen propusieron un enfoque interactivo asignación de aptitud-peso adaptativo, que es una mejora del enfoque de la asignación de aptitud-peso adaptativo con la

consideración de las desventajas de una suma ponderada planteamiento y enfoque basado en la clasificación de Pareto. En primer lugar, hay dos puntos extremos definidos como el punto máximo extremo $z^+ = \{ z_1^{max}, z_2^{max}, \dots, z_q^{max} \}$, y el mínimo punto extremo $z^- = \{ z_1^{min}, z_2^{min}, \dots, z_q^{min} \}$, donde z_k^{min} , y z_k^{max} donde son el valor máximo y el valor mínimo para el objetivo k en la población actual. Después, el peso adaptativo para el objetivo k se calcula mediante la siguiente ecuación:

Ecuación nº 9.24

$$w_k = \frac{1}{z_k^{max} - z_k^{min}}, \quad k = 1, 2, \dots, q$$

A continuación, calcular el término de penalización $p(v_i) = 0$, si v_i es una solución no dominada en el conjunto P de no dominados. De otro modo $p(v_i) = 1$ para la solución dominada v_i .

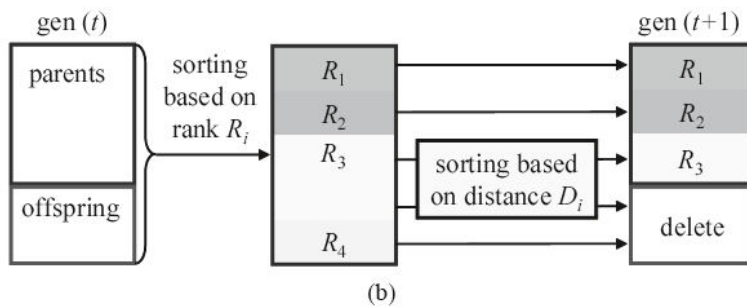



Figura nº 9.18 Ilustración de una nsGA II (caso de minimización)

Por último, el cálculo el valor de la aptitud de cada cromosoma mediante la combinación del método es de la siguiente manera:

Ecuación nº 9.25

$$eval(v_i) = \sum_{k=1}^q w_k (f_k(v_i) - z_k^{min}) + p(v_k), \quad \forall i \in popSize$$

9.9 Medidas de Rendimiento

Sea S_j un conjunto de soluciones ($j = 1, 2, \dots, J$). Con el fin de evaluar la eficiencia de los diferentes enfoques de asignación de aptitud, tenemos que definir las medidas de forma explícita evaluando la cercanía de S_j de un conjunto conocido de óptimo-Pareto el conjunto S^* . En este apartado, las siguientes tres medidas se considera que ya se utilizan en diferentes estudios de moGA. Proporcionan una buena estimación de la convergencia si establece una referencia para S^* (es decir, el conjunto de solución óptima de Pareto o un conjunto de solución óptima Pareto próximo).

Número de Soluciones Obtenidas | S_j |

Evaluar cada conjunto solución en función del número de soluciones obtenidas.

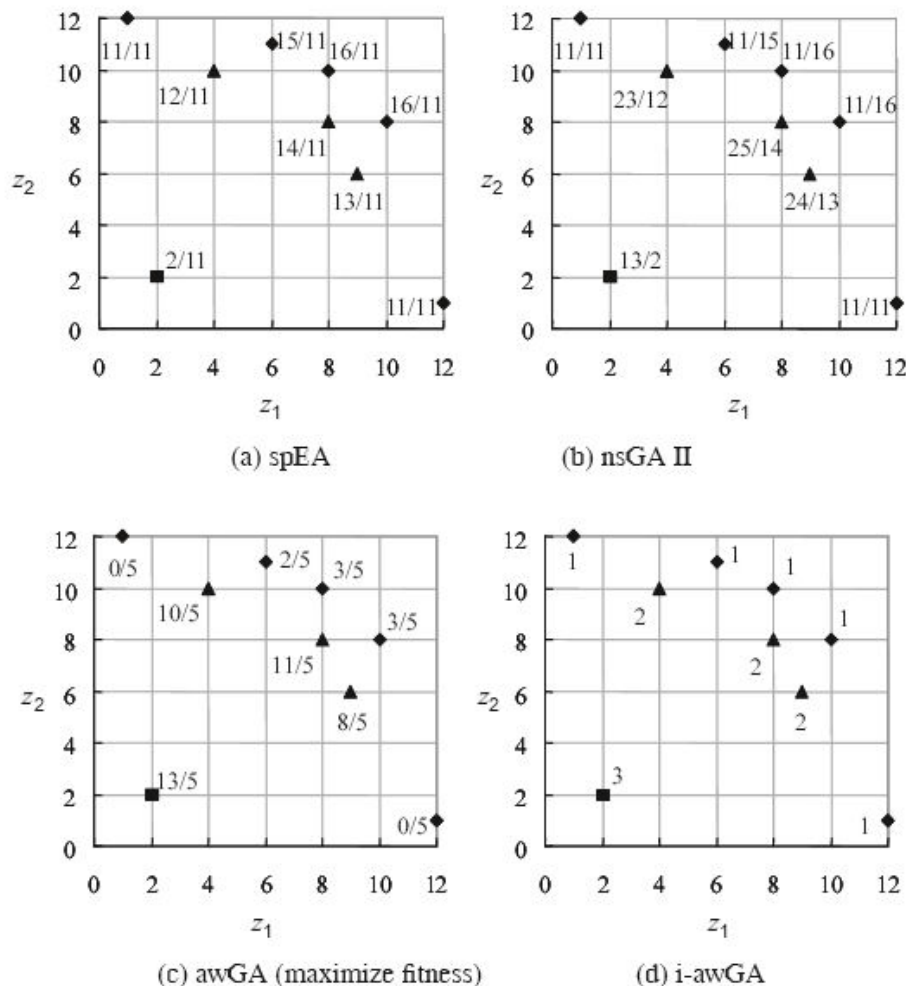


Figura nº 9.19 Ejemplo de valores de aptitud para diferentes mecanismos de asignación de aptitud. (caso de maximización)

Proporción de Soluciones no dominantes $R_{NDS}(S_j)$

Esta medida simplemente cuenta el número de soluciones que son miembros del conjunto óptimo de Pareto S^* . La medida del $R_{NDS}(S_j)$ se puede escribir de la siguiente manera:

Ecuación nº 9.26

$$R_{NDS}(S_j) = \frac{|S_j| - \{x \in S_j | \exists r \in S^*: r < x\}}{|S_j|}$$

donde $r < x$ significa que la solución x está dominada por la solución de r . Una $R_{NDS}(S_j) = 1$ significa que todas las soluciones son miembros del conjunto óptimo de Pareto S^* , y un $R_{NDS}(S_j) = 0$ significa que no es solución un miembro de la S^* . Es una medida importante que, aunque el número de soluciones obtenidas $-S_j-$ sea grande, si la relación de soluciones no dominadas $R_{NDS}(S_j)$ es 0, puede ser un resultado peor. La dificultad con las medidas anteriores es que, a pesar de un miembro de S_j es un óptimo de Pareto, si esa solución no existe en S^* , puede que no se contará en $R_{NDS}(S_j)$ como una solución no óptima de Pareto. Por lo tanto, es esencial que sea necesario en las ecuaciones anteriores un gran conjunto de S^* .

Ecuación nº 9.27

$$R_{NDS}(S_j) = \frac{|S_j| - \{x \in S_j | \exists r \in S^*: r < x\}}{|S_j|}$$

Distancia Media $D1_R(S_j)$

En lugar de encontrar si una solución de S_j pertenece al conjunto S^* o no, esta medida se encuentra una distancia media de las soluciones de S_j de S^* , como sigue:

Ecuación nº 9.28

$$D1_R(S_j) = \frac{1}{|S^*|} \sum_{r \in S^*} \min\{d_{rx} | x \in S_j\}$$

donde d_{rx} es la distancia entre una solución actual x y una solución de referencia r en el espacio objetivo normalizado de dos dimensiones

Ecuación nº 9.29

$$d_{rx} = \sqrt{(f_1(r) - f_1(x))^2 + (f_2(r) - f_2(x))^2}$$

Cuanto menor sea el valor de $D1_R(S_j)$, mejor será S_j el conjunto de soluciones. Esta medida de forma explícita calcula una medida de la cercanía de un conjunto de soluciones S_j del conjunto S^* .

9.9.1 Conjunto de referencia S^*

Con el fin de obtener un gran número de soluciones en el conjunto de referencia S^* , primero calculamos la solución fija con ajustes especiales de parámetros del AG y se utiliza un muy largo tiempo de cálculo tiempo por cada enfoque en los experimentos de comparación, a continuación, se combinan estas soluciones fijas para calcular el conjunto de referencia S^* . Además, combinaremos los pequeños ajustes razonables de parámetros del AG para los experimentos de comparación. De este modo asegurar la eficacia del conjunto de referencia S^*

10 Resultados y conclusiones

10.1 Resultados

A partir de las bases teóricas básicas establecidas en los capítulos anteriores 8 y 9 se estaría en condiciones para diseñar una red neuronal específica que sirva para resolver el problema inverso, en la aplicación de las corrientes inducidas.

Dicha red neuronal se desarrolla utilizando un software específico denominado Easy NN plus. Mediante el citado programa se generó una red neuronal multicapa básica con una primera capa de nodos de entrada (parámetros R resistencia y X reactancia), una segunda capa de nodos ocultos una tercera capa de salida (espesor de cada capa en micras). La Figura 10.1 muestra la ventana de generación de la red neuronal, mientras que la 10.2 muestra la red neuronal resultante.

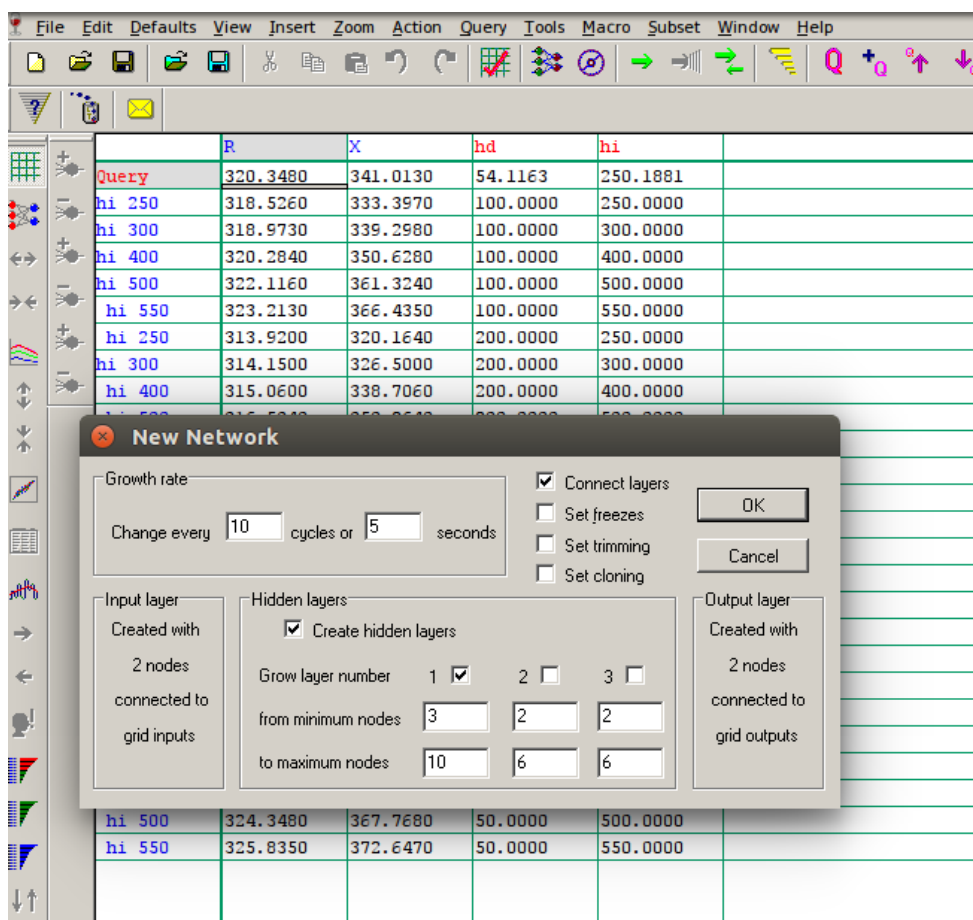


Figura nº 10.1 Ventana generación red neuronal

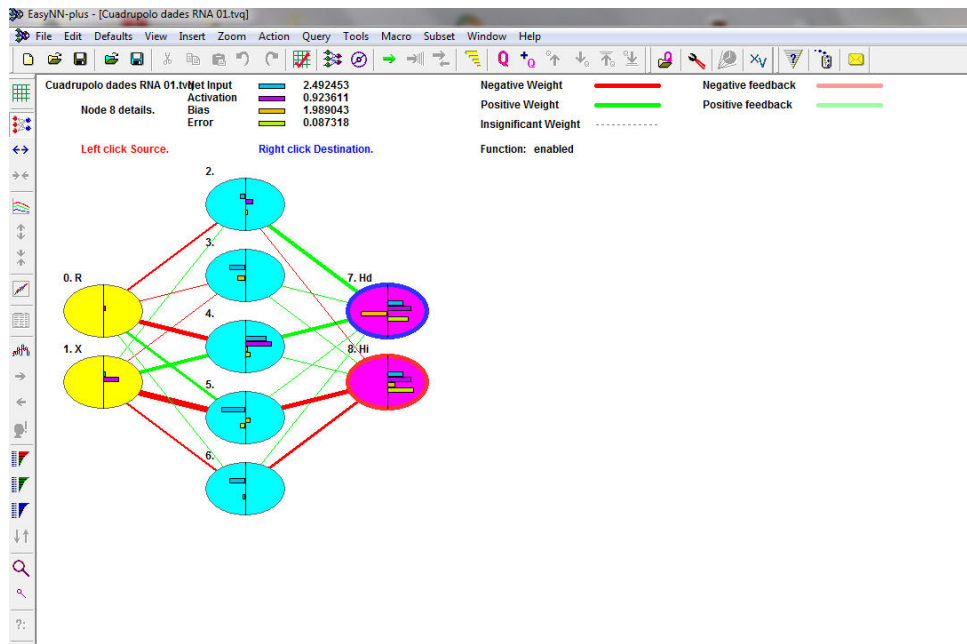


Figura nº 10.2 Red neural constituida

Seguidamente se procedió a entrenar la red siguiendo el algoritmo de retropropagacion descrito en los capítulos anteriores. La figura 10.3 muestra los parámetros de configuración del algoritmo de entrenamiento, mientras que la Figura 10.4 muestra los resultados del mismo.

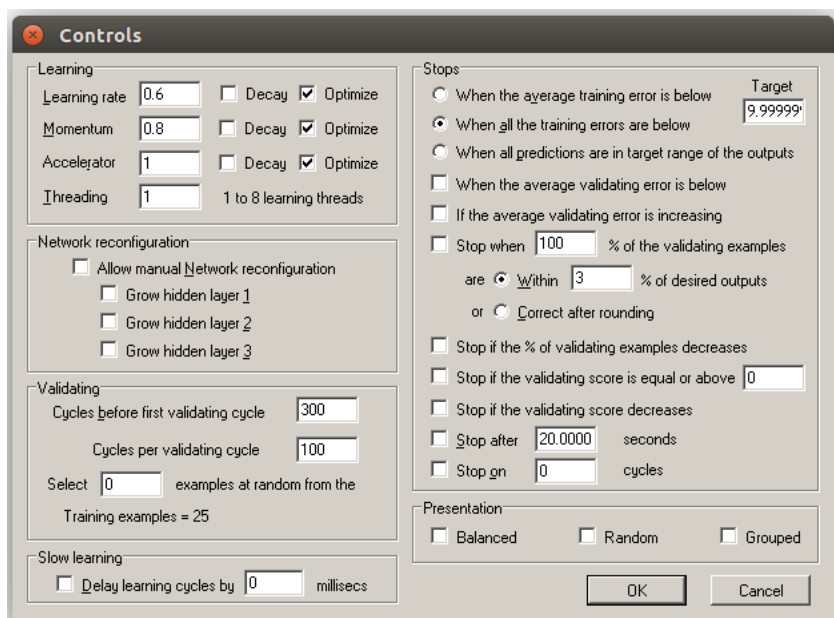


Figura nº 10.3 Controles




Figura nº 10.4 Ciclos de aprendizaje

Como se puede apreciar, el proceso de entrenamiento es convergente y tras 32 ciclos de entrenamiento puede considerarse que la red neuronal ha quedado ajustada.

Una vez definida y entrenada la red neuronal, se procedió a evaluar el error máximo para los datos de entrenamiento. Como se puede apreciar en la Figura 10.5, este error máximo es del 4%. Dado que el error de medición descrito es superior a este valor, puede considerarse que el error obtenido es aceptable.

Finalmente, se estimó la importancia de las variables de entrada, así como la sensibilidad de las variables de salida respecto a las variables de entrada, cuyos resultados pueden apreciarse en las Figuras 10.6 y 10.7. Como puede apreciarse, la medida de la resistencia R es más importante para definir la red neuronal que la impedancia, aunque ambas (R y X) tienen la misma influencia en las variables de salida.




Figura nº 10.5 Tabla de errores.




Figura nº 10.6 Tabla de errores.




Figura nº 10.7 Tabla de errores.

10.2 Conclusiones

En base a todo lo expuesto en el presente trabajo, se puede concluir que es posible determinar con precisión el espesor de cada capa de recubrimiento de protección, para los materiales analizados (Inconel y Duraniquel), sin aplicar métodos destructivos. Esto se logra en base a la aplicación del método desarrollado en este trabajo que se basa en la realización de mediciones mediante corrientes inducidas que posteriormente son tratadas por dos métodos:

- Un primer método que sirve para acotar el rango de espesor sin determinar el valor específico del mismo.
- Un segundo método que basado en una red neuronal establece patrones de comportamiento en las medidas de modo que sea posible determinar el espesor de cada capa de forma indirecta.

11 Líneas de trabajo futuras

11.1 Líneas de trabajo futuras

Considerando los resultados en el objetivo de obtener, una información sobre las características de las protecciones multicapa se hace necesario promover otras de investigación:

- Es necesario proseguir en el nuevo diseño de la bobina sensora, sobre todo en la confección de sensores de bobina plana sobre circuitos integrados. Aunque las pruebas realizadas nos indican que los valores de autoinducción son inferiores a los de la bobina convencional, cabe estudiar los resultados mediante la construcción de estos circuitos con una dimensiones mas reducidas (lo que aumenta la longitud del circuito y el número de espiras , hasta alcanzar valores de autoinducción que resulten viables (hay que recordar que en general las medidas de este parámetro se realizan por incremento diferencial) y eso conlleva valores muy inferiores a los usuales de las bobinas sensoras convencionales.
- Otro campo para explorar es la construcción de sensores múltiples, es decir conjuntos de bobinas en disposición equidistante que abarque una mayor zona de prospección.
- No menos interesante y donde ya hay alguna experiencia es el uso de señales pulsada, porque con ello y mediante el empleo de la transformadas de Fourier en el tiempo, es posible que se obtengan resultados mas convincentes por ser más precisos.
- En cualquiera de los tres supuestos citados, el objetivo no debería ser sólo mejorar la precisión en la obtención de espesores de la multicapa, sino además su caracterización es decir la obtención al mismo tiempo que del parámetro geométrico del espesor, obtener la conductividad y la permeabilidad del medio.

12 Anexos

12.1 Anexos ANSYS

12.1.1 Macros

Protección multicapa

```
/title,Corrents induïdes capes de protecció
/prep7
/nopr
et,1,plane53
hm=1250
ff=12000
mat,1,
mpread,'Acer','SI_MPL','',LIB
mat,2,
mpread,'ALENIAL','SI_MPL','',LIB
MAT,3,
mpread,'ACERCRFE','SI_MPL','',LIB
MAT,4,
mpread,'coure','SI_MPL','',LIB
h=0.002500
a=h/5
q=0.000100
rect,0,a,0,h
rect,0,a,h,h+q
rect,0,a,h+q,h+4*q
rect,0,a,h+4*q,h+4*q+a
aglue,all
numcomp,area
asel,s,area,,1
aatt,1,0,1
asel,s,area,,2
aatt,1,0,1
asel,s,area,,3
aatt,1,0,1
asel,s,area,,4
aatt,4,0,1
asel,all
esize,,3
mshkey,1
amesh,all
nset,s,loc,y,0
d,all,az,0
nset,s,loc,y,h+4*q+a
cp,1,az,all
nset,all
finish
/solu
antype,harmic
esel,s,mat,4
bfe,all,js,,0.,0.,hm/a,0.
esel,all
hmagsolv,ff
finish
/post1
set,last,1,0,
esel,mat,,1,3
powerh
finish
```

12.1.2 Elementos

PLANE53

PLANE53 2-D 8-Node Magnetic Solid


PLANE53 Descripción del Elemento

PLANE53 para modelos 2D de campos magnéticos (planos y de simetría axial). El elemento está definido por 8 nodos y tiene hasta cuatro G.D.L grados de libertad por nodo: **AZ** el componente z del potencial vector magnético, **VOLT** el potencial eléctrico escalar integrado en el tiempo, **CURR** corriente eléctrica y EMF la fuerza electromotriz.

PLANE53 está basado en la formulación del potencial vector magnético y es aplicable en baja frecuencia a diversos casos en magnetostática, transitorios y senoidal incluye las corrientes inducidas. El elemento tiene la capacidad para permeabilidades no lineales mediante modelado de curvas de magnetización B-H o curvas de desmagnetización en imanes permanentes.

Figura PLANE53 Geometría

Figura nº 12.1 PLANE53



PLANE53 Sumario de entradas

Nodos

I, J, K, L, M, N, O, P

Grados de libertad

AZ if KEYOPT(1) = 0

VOLT, AZ if KEYOPT(1) = 1 AZ

CURR if KEYOPT(1) = 2

AZ, CURR, EMF if KEYOPT(1) = 3 or 4

Constantes Reales

CARE, TURN, LENG, DIRZ, FILL,

VELOX, VELOY, OMEGAZ,
XLOC, YLOC

Propiedades Materiales

MUZERO, MURX, MURY,
RSVX,
MGXX, MGY Y,

Además tabla de datos BH

Cargas Superficiales**Fuerzas de Maxwell flag --**

cara 1 (J-I), cara 2 (K-J), cara 3 (L-K), cara 4 (I-L)

Cargas Másicas**Temperatura --**

T(I), T(J), T(K), T(L), T(M), T(N), T(O), T(P)

KEYOPT(1)

Grados de libertad del elemento:

- 0 -- AZ G.D.L. : dominio estático , dominio corrientes inducidas (eddy current)
- 1 -- VOLT, AZ G.D.L.: conductor masivo alimentación por corriente
- 2 -- AZ, CURR G.D.L: bobina solenoide, alimentación por voltaje
- 3 -- AZ, CURR, EMF G.D.L.: bobina solenoide circuito acoplado
- 4 -- AZ, CURR, EMF G.D.L. conductor masivo circuito acoplado

KEYOPT(2)

0 -- Elemento convencional con velocidad

1 -- Efectos de la velocidad ignorados

Formulación con velocidad convencional (no valido sí KEYOPT(1) = 2, 3, o 4)

KEYOPT(3)

Comportamiento del elemento:

0 -- Plano

1 -- Axisimétrico

KEYOPT(4)

Sistema de coordenadas del elemento

0 -- El sistema coordinado del elemento es paralelo al sistema de coordenadas global

1 -- El sistema coordinado esta basado en el lado I-J del elemento

Table 53.1 PLANE53 Constantes reales

No.	Name	Description
KEYOPT (1) 2 – Análisis con voltaje forzado o electromagnético con circuito acoplado (bobinas o conductores masivos)		
1	CARE	Área de la sección transversal; requerida con KEYOPT(1) = 2, 3, 4
2	TURN	Número total de espiras de la bobina (solo bobina devanada), por defecto es 1; KEYOPT(1) = 2, 3
3	LENG	Longitud de la bobina en la dirección Z , (requerido sólo modelos planos), por defecto es 1 metro ; KEYOPT(1) = 2, 3, 4
4	DIRZ	1 para corrientes en la dirección positiva del eje z , -1 para corrientes en la

No.	Name	Description
		dirección negativa del eje z . KEYOPT(1) = 2, 3, 4
5	FILL	Factor de relleno de la bobina; KEYOPT(1) = 2, 3
KEYOPT (2) = 1 (y KEYOPT(1) = 0 o 1) – Efectos de la velocidad de un conductor masivo.		
6	VELOX	Componente de velocidad en dirección X (global Cartesiano)
7	VELOY	Componente de velocidad en dirección Y (global Cartesiano)
8	OMEGAZ	Velocidad Angular (rotacional) (Hz, ciclos/s) alrededor el eje Z (global Cartesiano), en el punto de pivote.
9	XLOC	Punto de pivote localización X (coordenada global Cartesiana)
10	YLOC	Punto de pivote localización Y (coordenada global Cartesiana)

PLANE53 Salida de datos

Las soluciones de salida asociadas con este elemento se dan en dos formas:

G.D.L. incluidos en la solución nodal completa

Salidas adicionales del elemento como se muestra en la tabla de definiciones

Debido a las convenciones de signo diferentes para los sistemas de coordenadas Polar y Cartesiano, los vectores densidad de flujo magnético en direcciones opuestas para los análisis planos (KEYOPT(3) = 0) y axisimétricos (KEYOPT(3) = 1)

Tabla 53.2 PLANE53 Definiciones de Salidos del Elemento

Name	Definition	O	R
EL	Número de elemento	Y	Y
NODES	Nodos - I, J, K, L, M, N, O, P	Y	Y
MAT	Número de material	Y	Y
VOLU:	Volumen	Y	Y
XC, YC	Localización de los resultados	Y	<u>2</u>
CENT: X, Y	Localización global XC, YC	Y	Y
TEMP	Temperaturas T(I), T(J), T(K), T(L), T(M), T(N), T(O), T(P)	Y	Y
LOC	Localización de salida (X, Y)	<u>1</u>	-
MUX, MUY	Pemeabilidad magnética secante	<u>1</u>	<u>1</u>
H:X, Y	Componentes de la intensidad de campo magnético	<u>1</u>	<u>1</u>
H:SUM	Vector magnitud de H	<u>1</u>	<u>1</u>
B:X, Y	Componentes densidad de flujo magnético (X, Y)	<u>1</u>	<u>1</u>
B:SUM	Vector magnitud de B	<u>1</u>	<u>1</u>
JSZ	Densidad de corriente fuente , válida solo para análisis estáticos	<u>1</u>	<u>1</u>
JTZ	Densidad total de corriente	<u>1</u>	<u>1</u>
JHEAT:	Generación de calor Joule por unidad de volumen	<u>1</u>	<u>1</u>
FJB(X, Y)	Componentes de las fuerzas de Lorentz	<u>1</u>	<u>1</u>

Name	Definition	O	R
FMX(X, Y)	Componentes de las fuerzas de Maxwell	1	1
FVW(X, Y, SUM)	Componentes de fuerzas en trabajos virtuales	1	1
FMAG:X, Y	Componentes de fuerzas combinadas (FJB o FMX)	-	1
ERES	Valor de resistencia del Elemento (sólo para bobinas devanadas)	-	1
EIND	Valor de la inductancia del Elemento (sólo para bobinas devanadas)	-	1
DMUXX, DMUYY	Permeabilidad Diferencial	1	1
V:X, Y, SUM	Componentes de la Velocidad	1	1
MRE	Número de Reynolds magnético	1	1
TJB(Z)	Par de torsión de Lorentz alrededor del eje Z global Cartesian +Z-axis	1	1
TMX(Z)	Maxwell torque about global Cartesian +Z-axis	1	1
TVW(Z)	Virtual work torque about global Cartesian +Z-axis	1	1

Nota

JT representa la densidad de corriente total mensurable en un conductor, incluyendo los efectos de las corrientes inducidas, y los efectos de la velocidad si son calculados.

Los valores de Inductancia (EIND) obtenidos para KEYOPT(1) = 2, 3, o 4 son sólo válidos para las siguientes condiciones: el problema es lineal (permeabilidad constante), no hay imanes permanentes en el modelo, y sólo existe una bobina en el modelo.

PLANE53 Aceptaciones y restricciones

El área del elemento debe de ser positiva

Imanes permanentes no son permitidos en análisis armónicos.

Para análisis magnetostaticos , la opciones VOLT, AZ no se alcanzan.

Para análisis armónicos y transitorios (variables en el tiempo), ANSYS no soporta el análisis de los efectos de velocidad y circuitos acoplados.

No puede ser usado los métodos transitorios reducidos. Un análisis de los efectos piel de las corrientes inducidas (en los que la formación de las corrientes inducidas es permitida en regiones con corrientes de cargas impresas) se conforman con la herramienta KEYOPT(1) = 1, especificando una resistividad, y acoplando todos los G.D.L VOLT para elementos en cada una de las dichas regiones.

Para voltaje de campo magnético forzado (KEYOPT(1) = 2) y en problemas de circuitos acoplados (KEYOPT(1) = 3,4), considerar las siguientes restricciones:

Sólo unidades MKS son alcanzadas.

La permeabilidad y la conductividad deben de ser constantes e isotrópicas.

Todos los G.D.L CURR en la región de la bobina deben de ser acopladas (comando CP).

Todos los G.D.L EMF en la región de la bobina deben de ser acopladas (comando CP).

12.2 Anexos Mathcad

Mathcad nº 12.1

Efecto skin

$$\mu_0 := 4 \cdot \pi \cdot 10^{-7} \cdot \frac{\text{H}}{\text{m}}$$

$$\mu_r := 1$$

$$\sigma_{cu} := 58 \cdot 10^6 \cdot \frac{\text{S}}{\text{m}}$$

$$\sigma_{ac} := 5.74 \cdot 10^6 \cdot \frac{\text{S}}{\text{m}}$$

$$\sigma_{al} := 35.714 \cdot 10^6 \cdot \frac{\text{S}}{\text{m}}$$

$$\mu := \mu_r \cdot \mu_0$$

$$j := 1(\text{C})$$

$$f_0 := 10 \text{ Hz}$$

$$f_j := 1000 \text{ kHz}$$

$$h := \frac{f_j - f_0}{j}$$

$$n := 0..j$$

$$f_n := 100 \text{ Hz}$$

$$f_n := f_0 + n \cdot h$$

$$\omega_n := 2 \cdot \pi \cdot f_n$$


δ (mm)

f(Hz)

$$\delta_{cu_n} := \sqrt{\frac{2}{\omega_n \cdot \mu \cdot \sigma_{cu}}}$$

$$\delta_{ac_n} := \sqrt{\frac{2}{\omega_n \cdot \mu \cdot \sigma_{ac}}}$$

$$\delta_{al_n} := \sqrt{\frac{2}{\omega_n \cdot \mu \cdot \sigma_{al}}}$$



Cu Cobre
Ac Acero
Al Aluminio

Mathcad nº 12.2

Impedancia superficial y profundidad de penetración

$$a := 1\text{mn}$$

$$q := 400$$

$$h := \frac{a}{q \cdot \text{mm}}$$

$$x_0 := 0\text{mn}$$

$$n := 0..q$$

$$x_n := x_0 + n \cdot \frac{a - x_0}{q}$$

$$f := 60\text{kHz}$$

$$\omega := 2 \cdot \pi \cdot f$$

$$h = 2.5 \times 10^{-3}$$

$$\mu_r := 1$$

$$\mu_0 := 4 \cdot \pi \cdot 10^{-7} \cdot \frac{\text{H}}{\text{m}}$$

$$c := 299792456.4 \frac{\text{m}}{\text{s}}$$

$$\varepsilon := \frac{1}{c^2 \cdot \mu_0}$$

$$\sigma := 56 \cdot 10^6 \cdot \frac{\text{S}}{\text{m}}$$

$$\mu := \mu_r \cdot \mu_0$$

$$k := \sqrt{\omega^2 \cdot \mu \cdot \varepsilon - i \cdot \omega \cdot \mu \cdot \sigma}$$

$$k = (3.642 \times 10^3 - 3.642i \times 10^3) \frac{1}{\text{m}}$$

$$\delta := \sqrt{\frac{2}{\omega \cdot \mu \cdot \sigma}}$$



$$\delta = 274.568 \times 10^{-6} \text{ m}$$

$$Z_n := \frac{-\omega \cdot \mu}{k} \cdot \frac{\sinh(i \cdot k \cdot x_n)}{\cosh(i \cdot k \cdot x_n)}$$

$$R_n := \text{Re}(Z_n)$$

$$R_s := \frac{1}{\sigma \cdot \delta}$$

$$\theta_n := \text{atan} \left(\frac{\text{Im}(Z_n)}{\text{Re}(Z_n)} \right)$$



Mathcad n° 12.3

Pérdidas de potencia

$$N_s := 200$$

$$i := 0.. N_s$$

$$f_0 := 10\text{Hz}$$

$$f_n := 50\text{kHz}$$

$$H_{oz} := 10000\text{e}$$

$$f_i := f_0 + i \cdot \frac{f_n - f_0}{N_s}$$

$$\sigma := 20 \cdot 10^6 \cdot \frac{\text{S}}{\text{m}}$$

$$\mu := 4 \cdot \pi \cdot 10^{-7} \cdot \frac{\text{H}}{\text{m}}$$

$$\omega := 2 \cdot \pi \cdot f$$

$$a := 10\text{mm}$$


$$\delta := \sqrt{\frac{2}{\omega \cdot \mu \cdot \sigma}}$$

$$x := \frac{2 \cdot a}{\delta}$$

$$P_{o_i} := \frac{H_{oz}^2}{\sigma \cdot \delta} \cdot \frac{\sinh(x_i) - \sin(x_i)}{\cosh(x) + \cos(x)}$$

$$Q_o := H_{oz}^2 \cdot \frac{1}{3!} \cdot (a^3 \cdot \sigma) \cdot (\omega \cdot \mu)^2$$

$$R_o := \frac{H_{oz}^2}{\sigma \cdot \delta}$$



Mathcad n° 12.4

Diagrama impedancia/conductividad de la muestra

$$\sigma := 58 \cdot 10^6 \cdot \frac{\text{S}}{\text{m}}$$

$$\mu := 4\pi \cdot 10^{-7} \cdot \frac{\text{H}}{\text{m}}$$

$$c := 299792456.4 \frac{\text{m}}{\text{s}}$$

$$\epsilon := \frac{1}{c^2 \cdot \mu}$$

$$N_s := 1000$$

$$n := 1..N_s$$

$$\sigma_n := \left(\frac{\sigma}{N_s} \right) \cdot n$$

$$a := 10 \text{mm}$$

$$f := 10 \text{kHz}$$


$$\omega := 2 \cdot \pi \cdot f$$

$$\delta_n := \sqrt{\frac{2}{\omega \cdot \mu \cdot \sigma_n}}$$

$$x_n := \frac{2 \cdot a}{\delta_n}$$

$$k_n := \frac{1 - i}{\delta_n}$$

$$Z_n := \frac{1}{\sigma_n + i \cdot \omega \cdot \epsilon} \cdot \frac{\text{ber}(1, x_n) + i \cdot \text{bei}(1, x_n)}{\text{ber}(0, x_n) + i \cdot \text{bei}(0, x_n)}$$



Mathcad n° 12.5

Impedancia de una bobina/frecuencia

$$\sigma := 20 \cdot 10^6 \cdot \frac{\text{S}}{\text{m}}$$

$$\mu := 4\pi \cdot 10^{-7} \cdot \frac{\text{H}}{\text{m}}$$

$$c := 299792456.4 \frac{\text{m}}{\text{s}}$$

$$\epsilon := \frac{1}{c^2 \cdot \mu}$$

$$N_s := 1000$$

$$f_n := 500 \text{ Hz}$$

$$f_0 := 0.5 \text{ Hz}$$

$$a := 10 \text{ mm}$$

$$n := 0..N_s$$

$$f_n := f_0 + n \cdot \frac{f_n - f_0}{N_s}$$

$$\omega_n := 2 \cdot \pi \cdot f_n$$

$$\delta_n := \sqrt{\frac{2}{\omega_n \cdot \mu \cdot \sigma}}$$



$$x_n := \frac{2 \cdot a}{\delta_n}$$

$$k_n := \frac{1 - i}{\delta_n}$$

$$Z_n := \frac{1}{\sigma + i \cdot \omega_n \cdot \epsilon} \cdot \frac{\text{ber}(1, x_n) + i \cdot \text{bei}(1, x_n)}{\text{ber}(0, x_n) + i \cdot \text{bei}(0, x_n)}$$

$$L_{e_n} := \frac{-2}{\sqrt{2} \cdot k_n \cdot a} \cdot \frac{\text{ber}(1, x_n) + i \cdot \text{bei}(1, x_n)}{\text{ber}(0, x_n) + i \cdot \text{bei}(0, x_n)}$$

$$R_{f_n} := -\omega_n \cdot \text{Im}(L_{e_n})$$



Mathcad n° 12.6
Metodos numericos

Q :=



Impedancia Theo

$$\mu_0 := 4 \cdot \pi \cdot 10^{-7} \frac{\text{H}}{\text{m}}$$

$$f := 100 \text{ kHz}$$

$$\mu_r := 1$$

$$\sigma := 16.45 \cdot 10^6 \frac{\text{S}}{\text{m}}$$

$$\omega := 2 \cdot \pi \cdot f$$

$$r_1 := 3.015 \text{ mm}$$

$$r_2 := 5.46 \text{ mm}$$

$$z_1 := 1.32 \text{ mm}$$

$$z_2 := 4.26 \text{ mm}$$

$$N_e := 900$$

$$b := 10 \text{ } \mu\text{m}^2$$

$$x := Q^{(0)}$$

$$q := \frac{x}{b}$$

$$p := \sqrt{q^2 + i \cdot \omega \cdot \mu_0 \cdot \mu_r \cdot \sigma}$$

$$x_1 := q \cdot r_1$$

$$x_2 := q \cdot r_2$$

$$\text{Int}(\alpha, \beta) := \int_{\alpha}^{\beta} \xi \cdot J_1(\xi) \, d\xi$$

$$\theta := 450$$

$$k := 0.. \epsilon$$

$$\text{Int}(x_1, x_2) =$$


$7.7 \sum 10^{-3}$
0.046
0.133
0.281
...

$$x_{1_0} = 0.212$$

$$x_{2_0} = 0.383$$

$$x_{1_\theta} = 78.282$$

$$x_{2_\theta} = 141.764$$



$$Z_b := \frac{i \cdot \omega \cdot 2 \cdot \pi \cdot \mu_0 \cdot N e^2}{(r_2 - r_1)^2 \cdot (z_2 - z_1)^2}$$


$$Z_b = 7.777i \times 10^{16} \frac{1}{m^5} \Omega$$

$$\Delta Z := Z_b \cdot \sum_{k=0}^{\theta} \left| \left(\text{Int}(x1_k, x2_k) \right)^2 \cdot \frac{(\exp(-q_k \cdot z_1) - \exp(-q_k \cdot z_2))^2}{[(q_k \cdot b) \cdot J_0(q_k \cdot b)]^2 \cdot (q_k)^5} \cdot \frac{q_k \cdot \mu r - p_k}{(q_k \cdot \mu r + p_k)} \right|$$

$$Z_o := Z_b \cdot \sum_{k=0}^{\theta} \left| \left(\text{Int}(x1_k, x2_k) \right)^2 \cdot \frac{2[q_k \cdot (z_2 - z_1) - 1 + \exp[q_k \cdot (z_1 - z_2)]]}{[(q_k \cdot b) \cdot J_0(q_k \cdot b)]^2 \cdot (q_k)^5} \right|$$

$$Z_o = 3.783i \times 10^3 \Omega$$

$$\Delta Z = (76.249 - 642.355i) \Omega$$

$$R_s := \begin{pmatrix} 1 & 5.986 & 1.024 \cdot 10^{-6} & 3.192 \cdot 10^{-6} \\ 2 & 1.917 & 0.016 & 0.020 \\ 3 & 2.485 & 0.065 & 0.039 \\ 4 & 7.949 & 0.413 & 0.070 \\ 5 & 8.131 & 0.465 & 0.017 \\ 6 & 0.017 & 6.037 \cdot 10^{-4} & -9.746 \cdot 10^{-6} \\ 7 & 8.453 & 0.563 & -0.182 \\ 8 & 15.080 & 1.507 & -0.979 \\ 9 & 18.145 & 2.138 & -1.994 \\ 10 & 19.857 & 2.491 & -2.866 \\ 11 & 20.913 & 2.685 & -3.535 \\ 12 & 21.607 & 2.795 & -4.034 \\ 13 & 22.085 & 2.861 & -4.405 \\ 14 & 22.427 & 2.900 & -4.685 \\ 15 & 22.678 & 2.926 & -4.898 \\ 20 & 23.278 & 2.971 & -5.445 \\ 25 & 23.496 & 2.979 & -5.642 \\ 100 & 23.706 & 2.984 & -5.847 \end{pmatrix}$$


Mathcad n° 12.7

Problema inverso

	(14381.658707		(1182.565
	13370.334687		1220.134
	12743.968044		1410.375
	13985.792575		1265.812
	13696.177104		1182.596
	13319.936164		1278.213
	13105.219853		1150.95
	13449.078327		1218.639
	13684.031612		1066.558
	13064.90264		1176.381
	13455.940705		1157.397
	13850.557203		1031.149
fox :=	13254.514871	for :=	1185.507
	13873.111117		1208.097
	14015.621223		1126.986
	12891.260589		1423.218
	13284.09258		1324.924
	13362.593248		1253.5
	13889.432958		1226.014
	13894.542879		1219.627
	13293.011364		1188.172
	13521.746533		1098.61
	13434.170462		1120.229
	13010.51921		1230.888
	(11556.044658)		(1137.558)

	0		0		0			
	0	493.648		0	643.002			
	1	605.254		1	644.547			
	2	736.332		2	726.166			
	3	562.767		3	522.071			
	4	559.858		4	528.446			
	5	631.671		5	667.536			
	6	605.186		6	588.428			
	7	597.095		7	485.56			
	8	517.975		8	451.753			
	9	618.515		9	587.076			
	10	573.708		10	543.707			
	11	488.755		11	517.241			
hw(x,y) =	12	603.59	h =	12	645.03	hw(x,y) - h =	12	-41.44
	13	552.233		13	634.985		13	-82.752
	14	508.375		14	536.076		14	-27.702
	15	726.873		15	796.619		15	-69.746
	16	652.465		16	626.968		16	25.497
	17	618.382		17	577.707		17	40.675
	18	557.305		18	536.656		18	20.649
	19	554.442		19	524.196		19	30.246
	20	600.862		20	594.9		20	5.962
	21	545.54		21	554.235		21	-8.695
	22	562.019		22	556.65		22	5.369
	23	643.992		23	544.383		23	99.609
	24	749.824		24	832.725		24	-82.901
	25			25			25	

hw(x,y) espesores calculados

h espesores ópticos

hw(x,y)-h diferencias

12.2.1 Ceros de Bessel

Mathcad n° 12.8

Ceros de las funciones de Bessel

s	$j_{0,s}$	$J'_0(j_{0,s})$	$j_{1,s}$	$J'_1(j_{1,s})$	$j_{2,s}$	$J'_2(j_{2,s})$		
1	2.40482	55577	-0.51914	74973	3.83171	-0.40276	5.13562	-0.33967
2	5.52007	81103	+0.34026	48065	7.01559	+0.30012	8.41724	+0.27138
3	8.65372	79129	-0.27145	22999	10.17347	-0.24970	11.61984	-0.23244
4	11.79153	44391	+0.23245	98314	13.32369	+0.21836	14.79595	+0.20654
5	14.93091	77086	-0.20654	64331	16.47063	-0.19647	17.95982	-0.18773
6	18.07106	39679	+0.18772	88030	19.61586	+0.18006	21.11700	+0.17326
7	21.21163	66299	-0.17326	58942	22.76008	-0.16718	24.27011	-0.16170
8	24.35247	15308	+0.16170	15507	25.90367	+0.15672	27.42057	+0.15218
9	27.49347	91320	-0.15218	12138	29.04683	-0.14801	30.56920	-0.14417
10	30.63460	64684	+0.14416	59777	32.18968	+0.14061	33.71652	+0.13730
11	33.77582	02136	-0.13729	69434	35.33231	-0.13421	36.86286	-0.13132
12	36.91709	83537	+0.13132	46267	38.47477	+0.12862	40.00845	+0.12607
13	40.05842	57646	-0.12606	94971	41.61709	-0.12367	43.15345	-0.12140
14	43.19979	17132	+0.12139	86248	44.75932	+0.11925	46.29800	+0.11721
15	46.34118	83717	-0.11721	11989	47.90146	-0.11527	49.44216	-0.11343
16	49.48260	98974	+0.11342	91926	51.04354	+0.11167	52.58602	+0.10999
17	52.62405	18411	-0.10999	11430	54.18555	-0.10839	55.72963	-0.10685
18	55.76551	07550	+0.10684	78883	57.32753	+0.10537	58.87302	+0.10396
19	58.90698	39261	-0.10395	95729	60.46946	-0.10260	62.01622	-0.10129
20	62.04846	91902	+0.10129	34989	63.61136	+0.10004	65.15927	+0.09882
s	$j_{3,s}$	$J'_3(j_{3,s})$	$j_{4,s}$	$J'_4(j_{4,s})$	$j_{5,s}$	$J'_5(j_{5,s})$		
1	6.38016	-0.29827	7.58834	-0.26336	8.77148	-0.24543		
2	9.76102	+0.24942	11.06471	+0.23188	12.33860	+0.21743		
3	13.01520	-0.21828	14.37254	-0.20636	15.70017	-0.19615		
4	16.22347	+0.19644	17.61597	+0.18766	18.98013	+0.17993		
5	19.40942	-0.18005	20.82693	-0.17323	22.21780	-0.16712		
6	22.58273	+0.16718	24.01902	+0.16168	25.43034	+0.15669		
7	25.74817	-0.15672	27.19909	-0.15217	28.62662	-0.14799		
8	28.90835	+0.14801	30.37101	+0.14416	31.81172	+0.14059		
9	32.06485	-0.14060	33.53714	-0.13729	34.98878	-0.13420		
10	35.21867	+0.13421	36.69900	+0.13132	38.15987	+0.12861		
11	38.37047	-0.12862	39.85763	-0.12607	41.32638	-0.12366		
12	41.52072	+0.12367	43.01374	+0.12140	44.48932	+0.11925		
13	44.66974	-0.11925	46.16785	-0.11721	47.64940	-0.11527		
14	47.81779	+0.11527	49.32036	+0.11343	50.80717	+0.11167		
15	50.96503	-0.11167	52.47155	-0.10999	53.96303	-0.10838		
16	54.11162	+0.10839	55.62165	+0.10685	57.11730	+0.10537		
17	57.25765	-0.10537	58.77084	-0.10396	60.27025	-0.10260		
18	60.40322	+0.10260	61.91925	+0.10129	63.42205	+0.10003		
19	63.54840	-0.10004	65.06700	-0.09882	66.57289	-0.09765		
20	66.69324	+0.09765	68.21417	+0.09652	69.72289	+0.09543		
s	$j_{6,s}$	$J'_6(j_{6,s})$	$j_{7,s}$	$J'_7(j_{7,s})$	$j_{8,s}$	$J'_8(j_{8,s})$		
1	9.93611	-0.22713	11.08637	-0.21209	12.22509	-0.19944		
2	13.58929	+0.20525	14.82127	+0.19479	16.03777	+0.18569		
3	17.00382	-0.18726	18.28758	-0.17942	19.55454	-0.17244		
4	20.32079	+0.17305	21.64154	+0.16688	22.94517	+0.16130		
5	23.58608	-0.16159	24.93493	-0.15657	26.26681	-0.15196		
6	26.82015	+0.15212	28.19119	+0.14792	29.54566	+0.14404		
7	30.03372	-0.14413	31.42279	-0.14055	32.79580	-0.13722		
8	33.23304	+0.13727	34.63709	+0.13418	36.02562	+0.13127		
9	36.42202	-0.13131	37.83872	-0.12859	39.24045	-0.12603		
10	39.60324	+0.12606	41.03077	+0.12365	42.44389	+0.12137		
11	42.77848	-0.12139	44.21541	-0.11924	45.63844	-0.11719		
12	45.94902	+0.11721	47.39417	+0.11526	48.82593	+0.11342		
13	49.11577	-0.11343	50.56818	-0.11166	52.00769	-0.10998		
14	52.27945	+0.10999	53.73833	+0.10838	55.18475	+0.10684		
15	55.44059	-0.10685	56.90525	-0.10537	58.35789	-0.10395		
16	58.59961	+0.10396	60.06948	+0.10260	61.52774	+0.10129		
17	61.75682	-0.10129	63.23142	-0.10003	64.69478	-0.09882		
18	64.91251	+0.09882	66.39141	+0.09765	67.85943	+0.09652		
19	68.06689	-0.09652	69.54971	-0.09543	71.02200	-0.09438		
20	71.22013	+0.09438	72.70655	+0.09336	74.18277	+0.09237		

12.3 Anexo Equipamiento

12.3.1 Calibrado del equipo Defectoscop.-

Con el fin de estimar el grado de precisión de la medida se establece una lectura en pantalla en divisiones de 5 dB (atenuación de la señal) y se toma lectura del voltaje de salida . La no linealidad de las lecturas, lo que reduce la precisión de la medida hasta hacerla inutilizable.




Figura nº 12.2 Calibrado del equipo Defectoscop

12.4 Anexo Redes neurales artificiales

12.4.1 Ejemplo para Excel de la etapa de aprendizaje

Tabla nº 12.1 Ejemplo FUNCIÓN .AND.

	A	B	C	D	E	F	G	H	I	J	K	L
1					AND							
2		Ent. 0	Ent. 1	Ent. 2	Salida		0.1	Ratio	Aprendizaje			
3		-1	0	0	0							
4		-1	0	1	0							
5		-1	1	0	0							
6		-1	1	1	1							
7	Etapa					P0	P1	P2	Suma	Activa	Error	
8	Etapa 1	-1	0	0	0	0.3	0.5	-0.4	-0.3	0	0	
9		-1	0	1	0	0.3	0.5	-0.4	-0.7	0	0	
10		-1	1	0	0	0.3	0.5	-0.4	0.2	1	-1	
11		-1	1	1	1	0.4	0.4	-0.4	-0.4	0	1	no converge
12	Etapa 2	-1	0	0	0	0.3	0.5	-0.3	-0.3	0	0	
13		-1	0	1	0	0.3	0.5	-0.3	-0.6	0	0	
14		-1	1	0	0	0.3	0.5	-0.3	0.2	1	-1	
15		-1	1	1	1	0.4	0.4	-0.3	-0.3	0	1	no converge
16	Etapa 3	-1	0	0	0	0.3	0.5	-0.2	-0.3	0	0	
17		-1	0	1	0	0.3	0.5	-0.2	-0.5	0	0	
18		-1	1	0	0	0.3	0.5	-0.2	0.2	1	-1	
19		-1	1	1	1	0.4	0.4	-0.2	-0.2	0	1	no converge
20	Etapa 4	-1	0	0	0	0.3	0.5	-0.1	-0.3	0	0	
21		-1	0	1	0	0.3	0.5	-0.1	-0.4	0	0	
22		-1	1	0	0	0.3	0.5	-0.1	0.2	1	-1	
23		-1	1	1	1	0.4	0.4	-0.1	-0.1	0	1	no converge
24	Etapa 5	-1	0	0	0	0.3	0.5	0.0	-0.3	0	0	
25		-1	0	1	0	0.3	0.5	0.0	-0.3	0	0	
26		-1	1	0	0	0.3	0.5	0.0	0.2	1	-1	
27		-1	1	1	1	0.4	0.4	0.0	0	0	1	no converge
28	Etapa 6	-1	0	0	0	0.3	0.5	0.1	-0.3	0	0	
29		-1	0	1	0	0.3	0.5	0.1	-0.2	0	0	
30		-1	1	0	0	0.3	0.5	0.1	0.2	1	-1	
31		-1	1	1	1	0.4	0.4	0.1	0.1	1	0	no converge
32	Etapa 7	-1	0	0	0	0.4	0.4	0.1	-0.4	0	0	
33		-1	0	1	0	0.4	0.4	0.1	-0.3	0	0	
34		-1	1	0	0	0.4	0.4	0.1	0	0	0	
35		-1	1	1	1	0.4	0.4	0.1	0.1	1	0	converge

Tabla nº 12.2 Ejemplo FUNCIÓN .OR:

	A	B	C	D	E	F	G	H	I	J	K	L	M
1					OR								
2		Ent. 0	Ent. 2	Salida		0.1	Ratio	Aprendizaje					
3		-1	0	0	0								
4		-1	0	1	1								
5		-1	1	0	1								
6		-1	1	1	1								
7	Etapa					P0	P1	P2	Suma	Activa	Error		
8	Etapa	-1	0	0	0	0.3	0.5	-0.4	-0.3	0	0		
9		-1	0	1	1	0.3	0.5	-0.4	-0.7	0	1		
10		-1	1	0	1	0.2	0.5	-0.3	0.3	1	0		
11		-1	1	1	1	0.2	0.5	-0.3	0.0	0	1	no converge	
12	Etapa	-1	0	0	0	0.1	0.6	-0.2	-0.1	0	0		
13		-1	0	1	1	0.1	0.6	-0.2	-0.3	0	1		
14		-1	1	0	1	0.0	0.6	-0.1	0.6	1	0		
15		-1	1	1	1	0.0	0.6	-0.1	0.5	1	0	no converge	
16	Etapa	-1	0	0	0	0.0	0.6	-0.1	0.0	0	0		
17		-1	0	1	1	0.0	0.6	-0.1	-0.1	0	1		
18		-1	1	0	1	-0.1	0.6	0.0	0.7	1	0		
19		-1	1	1	1	-0.1	0.6	0.0	0.7	1	0	no converge	
20	Etapa	-1	0	0	0	-0.1	0.6	0.0	0.1	1	-1		
21		-1	0	1	1	0.0	0.6	0.0	0.0	0	1		
22		-1	1	0	1	-0.1	0.6	0.1	0.7	1	0		
23		-1	1	1	1	-0.1	0.6	0.1	0.8	1	0	no converge	
24	Etapa	-1	0	0	0	-0.1	0.6	0.1	0.1	1	-1		
25		-1	0	1	1	0.0	0.6	0.1	0.1	1	0		
26		-1	1	0	1	0.0	0.6	0.1	0.6	1	0		
27		-1	1	1	1	0.0	0.6	0.1	0.7	1	0	no converge	
28	Etapa	-1	0	0	0	0.0	0.6	0.1	0.0	0	0		
29		-1	0	1	1	0.0	0.6	0.1	0.1	1	0		
30		-1	1	0	1	0.0	0.6	0.1	0.6	1	0		
31		-1	1	1	1	0.0	0.6	0.1	0.7	1	0	converge	

Tabla nº 12.3 Ejemplo Función .AND:

		NAND										
		Ent. 0	Ent. 1	Ent. 2	Salida	0.1 Ratio Aprendizaje						
		-1	0	0	1							
		-1	0	1	1							
		-1	1	0	1							
		-1	1	1	0							
Etapa					P0	P1	P2	Suma	Activa	Error		
Etapa 1		-1	0	0	1	0.3	0.5	-0.4	-0.3	0	1	
		-1	0	1	1	0.2	0.5	-0.4	-0.6	0	1	
		-1	1	0	1	0.1	0.5	-0.3	0.4	1	0	
		-1	1	1	0	0.1	0.5	-0.3	0.1	1	-1	no converge
Etapa 2		-1	0	0	1	0.2	0.4	-0.4	-0.2	0	1	
		-1	0	1	1	0.1	0.4	-0.4	-0.5	0	1	
		-1	1	0	1	0.0	0.4	-0.3	0.4	1	0	
		-1	1	1	0	0.0	0.4	-0.3	0.1	1	-1	no converge
Etapa 3		-1	0	0	1	0.1	0.3	-0.4	-0.1	0	1	
		-1	0	1	1	0.0	0.3	-0.4	-0.4	0	1	
		-1	1	0	1	-0.1	0.3	-0.3	0.4	1	0	
		-1	1	1	0	-0.1	0.3	-0.3	0.1	1	-1	no converge
Etapa 4		-1	0	0	1	0.0	0.2	-0.4	0	0	1	
		-1	0	1	1	-0.1	0.2	-0.4	-0.3	0	1	
		-1	1	0	1	-0.2	0.2	-0.3	0.4	1	0	
		-1	1	1	0	-0.2	0.2	-0.3	0.1	1	-1	no converge
Etapa 5		-1	0	0	1	-0.1	0.1	-0.4	0.1	1	0	
		-1	0	1	1	-0.1	0.1	-0.4	-0.3	0	1	
		-1	1	0	1	-0.2	0.1	-0.3	0.3	1	0	
		-1	1	1	0	-0.2	0.1	-0.3	0	0	0	no converge
Etapa 6		-1	0	0	1	-0.2	0.1	-0.3	0.2	1	0	
		-1	0	1	1	-0.2	0.1	-0.3	-0.1	0	1	
		-1	1	0	1	-0.3	0.1	-0.2	0.4	1	0	
		-1	1	1	0	-0.3	0.1	-0.2	0.2	1	-1	no converge
Etapa 7		-1	0	0	1	-0.2	0.0	-0.3	0.2	1	0	
		-1	0	1	1	-0.2	0.0	-0.3	-0.1	0	1	
		-1	1	0	1	-0.3	0.0	-0.2	0.3	1	0	
		-1	1	1	0	-0.3	0.0	-0.2	0.1	1	-1	no converge
Etapa 8		-1	0	0	1	-0.2	-0.1	-0.3	0.2	1	0	
		-1	0	1	1	-0.2	-0.1	-0.3	-0.1	0	1	
		-1	1	0	1	-0.3	-0.1	-0.2	0.2	1	0	
		-1	1	1	0	-0.3	-0.1	-0.2	0	0	0	no converge
Etapa 9		-1	0	0	1	-0.3	-0.1	-0.2	0.3	1	0	
		-1	0	1	1	-0.3	-0.1	-0.2	0.1	1	0	
		-1	1	0	1	-0.3	-0.1	-0.2	0.2	1	0	
		-1	1	1	0	-0.3	-0.1	-0.2	0	0	0	converge

Tabla nº 12.4 Ejemplo FUNCIÓN .NOR.

				NOR							
	Ent. 0	Ent. 1	Ent. 2	Salida	0.1	Ratio	Aprendizaje				
	-1	0	0	1							
	-1	0	1	0							
	-1	1	0	0							
	-1	1	1	0							
Etapa					P0	P1	P2	Suma	Activa	Error	
Etapa 1	-1	0	0	1	0.3	0.5	-0.4	-0.3	0	1	
	-1	0	1	0	0.2	0.5	-0.4	-0.6	0	0	
	-1	1	0	0	0.2	0.5	-0.4	0.3	1	-1	
	-1	1	1	0	0.3	0.4	-0.4	-0.3	0	0	no converge
Etapa 2	-1	0	0	1	0.3	0.4	-0.4	-0.3	0	1	
	-1	0	1	0	0.2	0.4	-0.4	-0.6	0	0	
	-1	1	0	0	0.2	0.4	-0.4	0.2	1	-1	
	-1	1	1	0	0.3	0.3	-0.4	-0.4	0	0	no converge
Etapa 3	-1	0	0	1	0.3	0.3	-0.4	-0.3	0	1	
	-1	0	1	0	0.2	0.3	-0.4	-0.6	0	0	
	-1	1	0	0	0.2	0.3	-0.4	0.1	1	-1	
	-1	1	1	0	0.3	0.2	-0.4	-0.5	0	0	no converge
Etapa 4	-1	0	0	1	0.3	0.2	-0.4	-0.3	0	1	
	-1	0	1	0	0.2	0.2	-0.4	-0.6	0	0	
	-1	1	0	0	0.2	0.2	-0.4	0	0	0	
	-1	1	1	0	0.2	0.2	-0.4	-0.4	0	0	no converge
Etapa 5	-1	0	0	1	0.2	0.2	-0.4	-0.2	0	1	
	-1	0	1	0	0.1	0.2	-0.4	-0.5	0	0	
	-1	1	0	0	0.1	0.2	-0.4	0.1	1	-1	
	-1	1	1	0	0.2	0.1	-0.4	-0.5	0	0	no converge
Etapa 6	-1	0	0	1	0.2	0.1	-0.4	-0.2	0	1	
	-1	0	1	0	0.1	0.1	-0.4	-0.5	0	0	
	-1	1	0	0	0.1	0.1	-0.4	0	0	0	
	-1	1	1	0	0.1	0.1	-0.4	-0.4	0	0	no converge
Etapa 6	-1	0	0	1	0.2	0.1	-0.4	-0.2	0	1	
	-1	0	1	0	0.1	0.1	-0.4	-0.5	0	0	
	-1	1	0	0	0.1	0.1	-0.4	0	0	0	
	-1	1	1	0	0.1	0.1	-0.4	-0.4	0	0	no converge
Etapa 7	-1	0	0	1	0.1	0.1	-0.4	-0.1	0	1	
	-1	0	1	0	0.0	0.1	-0.4	-0.4	0	0	
	-1	1	0	0	0.0	0.1	-0.4	0.1	1	-1	
	-1	1	1	0	0.1	0.0	-0.4	-0.5	0	0	no converge
Etapa 8	-1	0	0	1	0.1	0.0	-0.4	-0.1	0	1	
	-1	0	1	0	0.0	0.0	-0.4	-0.4	0	0	
	-1	1	0	0	0.0	0.0	-0.4	0	0	0	
	-1	1	1	0	0.0	0.0	-0.4	-0.4	0	0	no converge
Etapa 9	-1	0	0	1	0.0	0.0	-0.4	0	0	1	
	-1	0	1	0	-0.1	0.0	-0.4	-0.3	0	0	
	-1	1	0	0	-0.1	0.0	-0.4	0.1	1	-1	
	-1	1	1	0	0.0	-0.1	-0.4	-0.5	0	0	no converge
Etapa 10	-1	0	0	1	0.0	-0.1	-0.4	0	0	1	
	-1	0	1	0	-0.1	-0.1	-0.4	-0.3	0	0	
	-1	1	0	0	-0.1	-0.1	-0.4	0	0	0	
	-1	1	1	0	-0.1	-0.1	-0.4	-0.4	0	0	no converge
Etapa 11	-1	0	0	1	-0.1	-0.1	-0.4	0.1	1	0	
	-1	0	1	0	-0.1	-0.1	-0.4	-0.3	0	0	
	-1	1	0	0	-0.1	-0.1	-0.4	0	0	0	
	-1	1	1	0	-0.1	-0.1	-0.4	-0.4	0	0	converge

12.4.2 Derivación del algoritmo de retropropagación

A continuación se presenta una derivación de la algoritmo de entrenamiento de retropropagación, tal como se presenta por Ham y Kostanic (2001).

Utilizando un enfoque de gradiente de descenso más empinado, la regla de aprendizaje para un peso de red en una cualquiera de las capas de la red está dada por

Ecuación n° 12.1

$$\Delta w_{ji} = -\varepsilon \cdot \frac{\delta E}{\delta w_{ji}}$$

Utilizando la regla de la cadena para derivadas parciales, esta fórmula se puede reescribir como

Ecuación n° 12.2

$$\Delta w_{ji} = -\varepsilon \cdot \frac{\delta E}{\delta v_j} \frac{\delta v_j}{\delta w_{ji}}$$

donde v_j es el nivel de activación de la neurona j .

El último término en Ecuación n° 12.2 se puede evaluar como

Ecuación n° 12.3

$$\frac{\delta v_j^{(s)}}{\delta w_{ji}^{(s)}} = \frac{\delta}{\delta w_{ji}^{(s)}} \left(\sum_{h=1}^n (w_{ji}^{(s)} \cdot y_h^{(s-1)}) \right) = y_i^{(s-1)}$$

La primera derivada parcial de la Ecuación n° 12.2 es diferente para los pesos de las neuronas en capas ocultas y neuronas en capas de salida. Para las capas de salida, que puede ser escrito como

Ecuación n° 12.4

$$\frac{\delta E}{\delta v_j^{(s)}} = \frac{\delta}{\delta v_j^{(s)}} \left\{ \frac{1}{2} \sum_{h=1}^n [t_h - f(v_h^{(s)})]^2 \right\} = [t_j - f(v_j^{(s)})] g(v_j^{(s)})$$

o finalmente:

Ecuación n° 12.5

$$\frac{\delta E}{\delta v_j^{(s)}} = [t_j - f(v_j^{(s)})] g(v_j^{(s)}) \hat{=} -\delta_j^{(s)}$$

donde g representa la primera derivada de la función de activación f . El término se define en Ecuación n° 12.5 es comúnmente conocida como *error local*.

Para las neuronas en las capas ocultas, esta primera derivada parcial de la Ecuación n° 12.2 es más compleja ya que el cambio en la $v_j^{(s)}$ se propaga a través de la capa de salida de la red y afecta a todas las salidas de la red. Expresada esta cantidad como una función de las cantidades que ya son conocidas y de otros términos, los cuales se evalúan fácilmente nos da

Ecuación n° 12.6

$$\frac{\delta E}{\delta v_j^{(s)}} = \frac{\delta}{\delta y_j^{(s)}} \left\{ \frac{1}{2} \sum_{h=1}^n \left[t_h - f \left(\sum_{p=1}^{n^{(s)}} (w_{hp}^{(s+1)} \cdot y_p^{(s)}) \right) \right]^2 \right\} \frac{\delta y_j^{(s)}}{\delta v_j^{(s)}}$$

o bien

Ecuación n° 12.7

$$\begin{aligned} \frac{\delta E}{\delta v_j^{(s)}} &= - \left[\sum_{h=1}^{n^{(s+1)}} (t_h - y_j^{(s+1)}) g(v_h^{(s+1)}) w_{hj}^{(s+1)} \right] g(v_h^{(s)}) = \left(\sum_{h=1}^{n^{(s+1)}} \delta_h^{(s+1)} \cdot w_{hj}^{(s+1)} \right) g(v_j^{(s)}) \\ &= -\delta_j^{(s)} \end{aligned}$$

Combinando las ecuaciones Ecuación n° 12.2 Ecuación n° 12.3 con Ecuación n° 12.5 o Ecuación n° 12.7 fluye

Ecuación n° 12.8

$$\Delta w_{ji}^{(s)} = \varepsilon^s \cdot \delta_j^{(s)} \cdot y_i^{(s-1)}$$

o bien

Ecuación n° 12.9

$$w_{ji}^{(s)}(k+1) = w_{ji}^{(s)}(k) + \varepsilon^s \cdot \delta_j^{(s)} y_i^{(s-1)}$$

Vemos que las ecuaciones de actualización de los pesos en la capa oculta y la capa de salida tienen la misma forma. La única diferencia radica en la forma en que los errores

locales se calculan. Para la capa de salida, el error local es proporcional a la diferencia entre la salida deseada y la salida real de la red.

Al extender el mismo concepto a las "salidas" de las capas ocultas, el error local para una neurona en una capa oculta se puede ver como proporcional a la diferencia entre la salida deseada y la salida real de la neurona particular. Salidas por supuesto, durante el proceso de formación, las deseadas salidas de la neurona en la capa oculta no se conocen, y por lo tanto los errores locales tiene que ser estimado de forma recursiva en función de las señales de error de todas las neuronas conectadas.

Concluyendo, los pesos de la red se actualizan de acuerdo con la siguiente fórmula:

Ecuación nº 12.10

$$w_{ji}^{(s)}(k+1) = w_{ji}^{(s)}(k) + \varepsilon^s \cdot \delta_j^{(s)} y_i^{(s-1)}$$

donde

Ecuación nº 12.11

$$\delta_j^{(s)} = (t_{qh} - y_j^{(s)}) g(v_j^{(s)})$$

para cada capa de salida, y

Ecuación nº 12.12

$$\delta_j^{(s)} = \left(\sum_{h=1}^{n^{(s+1)}} \delta_h^{(s+1)} \cdot w_{hj}^{(s+1)} \right) g(v_j^{(s)})$$

para cada capa oculta.

12.4.3 El algoritmo de retropropagación

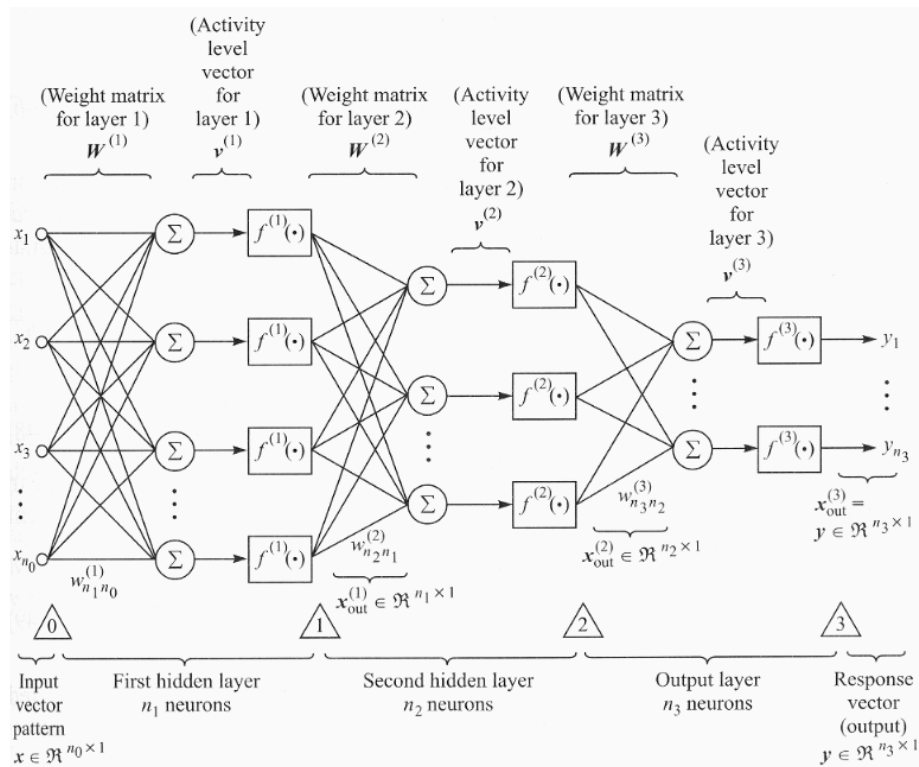


Figura nº 12.3 Ejemplo de una red MLP feedforward con tres capas.

A continuación se muestra una descripción del algoritmo de backpropagation. La Figura nº 12.3 puede resultar útil cuando se lee lo siguiente.

Paso 1. Inicializar los pesos de la red a los pequeños valores aleatorios.

A menudo se aplica un algoritmo de inicialización. Algoritmos de inicialización pueden mejorar la velocidad de entrenamiento de la red al hacer decisiones inteligentes para los pesos iniciales basadas en la arquitectura de la red.

Paso 2. En el conjunto de formación pares de entrada / pares de salida $(x_1, t_1), (x_2, t_2), \dots, (x_k, t_k)$ presentan un patrón de entrada y calculan la respuesta de la red.

Los valores del vector de entrada son x_1 de entrada para la capa de entrada de la red. Estos valores se pasan a través de la red. Las funciones de sesgo, de pesos de la red y la de activación transforman este vector de entrada a un y_1 vector de salida.

Paso 3. La respuesta de la red deseada se compara con la salida real de la red y el error puede ser determinado.

La función de error que tiene que ser minimizada mediante el algoritmo de backpropagation tiene la forma

Ecuación nº 12.13

$$E = \sum_{h=1}^n (t_h - y_h)^2$$

en la y es la salida calculada por la red y t la salida de la red deseada y n es el número de neuronas de salida.

Posteriormente, los *errores locales* se pueden calcular para cada neurona. Estos errores locales son el resultado de retropropagación de los errores de salida de nuevo en la red. Ellos son función de:

Los errores en las siguientes capas. Estos son o bien los errores de salida de la red (en el cálculo de los errores locales en la capa de salida) o los errores locales en la siguiente capa (en el cálculo de los errores locales en las capas ocultas y la entrada capa).

La derivada de la función de transferencia en la capa. Por esta razón, funciones de transferencia continuas son deseables.

Las fórmulas exactas se muestran en el paso 4.

Paso 4. Los pesos de la red se actualizan.

Los pesos de la red se actualizan de acuerdo con la siguiente fórmula (a menudo referida como la regla delta):

Ecuación nº 12.14

$$w_{ij}^{(s)}(k+1) = w_{ij}^{(s)}(k) + \varepsilon \cdot \delta_j^{(s)} \cdot y_i^{(s-1)}$$

$w_{ij}(k+1)$ y $w_{ij}(k)$ son los pesos entre neurona i y j durante el $(k+1)$ y k ésimo paso, etapa, o época. Una ecuación similar se puede escribir para la corrección de los valores de sesgo.

El δ error local se calcula de acuerdo con la

Ecuación nº 12.15

$$\delta_j^{(s)} = (t_{qh} - y_j^{(s)}) g'(v_j^{(s)})$$

para la capa de salida, y de acuerdo con

Ecuación nº 12.16

$$\delta_j^{(s)} = \left(\sum_{h=1}^{n_{s+1}} \delta_h^{(s+1)} \cdot w_{hj}^{(s)} \right) g \left(v_j^{(s)} \right)$$

para las capas ocultas. En estas fórmulas, la función g es la primera derivada de la función de transferencia f en la capa.

El parámetro ε en la Ecuación nº 12.13 es la denominada tasa de aprendizaje. Una tasa de aprendizaje se utiliza para aumentar la posibilidad de evitar el proceso de formación que se atrapado en mínimos locales en lugar de los mínimos global. Muchos paradigmas de aprendizaje hacen uso de un factor de tasa de aprendizaje.

Si una tasa de aprendizaje es demasiado alto, la regla de aprendizaje puede 'saltar' una solución óptima, pero un factor de aprendizaje demasiado pequeño puede resultar en un procedimiento de aprendizaje que evoluciona demasiado gradual.

Paso 5. Hasta que la red alcanza un nivel predeterminado de precisión produciendo la respuesta adecuada para todos los patrones de entrenamiento, siga los pasos 2 a 4.

Una variante conocida de esta forma clásica es el algoritmo de retropropagación con el impulso de actualización. La idea del algoritmo es para actualizar los pesos en la dirección, que es una combinación lineal del gradiente actual de la superficie de error y el obtenido en el paso anterior del entrenamiento. La única diferencia con el método de retropropagación que se ha mencionado anteriormente es la forma los pesos se actualizan:

$$w_{ij}^{(s)}(k+1) = w_{ij}^{(s)}(k) + \varepsilon \cdot \left[\delta_j^{(s)}(k) \cdot (k)y_i^{(s-1)} + \alpha \delta_j^{(s)}(k-1)y_i^{(s-1)}(k-1) \right]$$

En esta ecuación, α se llama factor de impulso. Por lo general se elige en el intervalo (0, 1). El factor de impulso puede acelerar la formación en regiones muy planas de la superficie de error y ayudar a prevenir oscilaciones en los pesos mediante la introducción de la estabilización en los cambios de peso

12.4.4 El algoritmo de backpropagation con gradiente conjugado

A continuación se presenta una descripción del algoritmo de backpropagation con el gradiente conjugado

La Figura nº 12.3 puede resultar útil para examinar el algoritmo siguiente.

Paso 1. Inicializar los pesos de la red para pequeños valores aleatorios.

Paso 2. Propagar el patrón de entrenamiento $q_{\text{ésimo}}$ sobre toda la red, calculando cálculo de la salida de cada neurona.

Paso 3. Calcular el error local en cada neurona en la red.

Para las neuronas de salida se calcula el error local como

Ecuación nº 12.17

$$\delta_{j,q}^{(s)} = (t_{j,q} - y_{j,q}^{(s)}) g(v_{j,q}^{(s)})$$

y para las neuronas de la capa oculta:

Ecuación nº 12.18

$$\delta_{j,q}^{(s)} = \left(\sum_{h=1}^{n_{s+1}} \delta_{h,q}^{(s+1)} \cdot w_{hj}^{(s+1)} \right) g(v_{j,q}^{(s)})$$

donde g es la derivada de la función de activación f .

Paso 4. Calcular el valor de salida deseado para cada una de las estimadas combinaciones lineales.

Haciendo referencia a la Figura B.1, vemos que cada una de las neuronas consiste en elementos de proceso adaptativo lineal (comúnmente conocida como combinadores lineales) seguidos no linealidades sigmoideas. Los combinadores lineales se representan por el símbolo Σ . Podemos observar que la salida de la función de activación no lineal será la respuesta deseada si el combinador lineal produce una entrada apropiada para la función de activación. Por consiguiente, podemos concluir que el entrenamiento de la red esencialmente consiste en el ajuste de los pesos de manera que cada uno de combinadores lineales de la red produce el resultado correcto.

Para cada una de las estimaciones combinador lineal, el valor de salida deseado es

Ecuación nº 12.19

$$\hat{v}_{j,q}^{(s)} = f^{-1}(\bar{d}_{j,q}^{(s)})$$

donde

Ecuación nº 12.20

$$\bar{d}_{j,q}^{(s)} = \bar{y}_{j,q}^{(s)} + \mu \cdot \bar{\delta}_{j,q}^{(s)}$$

es la salida deseada estimado de la j -ésima neurona en la capa de STH a la formación q th patrón. La función f^{-1} es la inversa de la función de activación. El parámetro es μ algún número positivo comúnmente tomada en el intervalo de 10 a 400.

Paso 5. Actualización de la estimación de la matriz de covarianza en cada capa y la estimación de la vector de correlación cruzada para cada neurona.

El algoritmo de gradiente conjugado asume un conocimiento explícito de la covarianza matrices y los vectores de correlación cruzada. Por supuesto, no se conocen de antemano y tienen que ser estimado durante el proceso de formación. Una forma cómoda de hacerlo es para actualizar sus estimaciones con cada presentación de la pareja de formación de entrada / salida.

La matriz de covarianza de las entradas del vector a la s -ésima capa se estima

Ecuación nº 12.21

$$C^s(k) = b \cdot C^s(k-1) + y_q^{(s-1)} \cdot y_q^{(s-1)T}$$

y el vector de correlación cruzada entre las entradas a la capa de s -ésima y la salida deseada del combinador lineal por

Ecuación nº 12.22

$$p_j^{(s)}(k) = b \cdot p_j^{(s)}(k-1) + v_j^{(s)} \cdot y_q^{(s-1)}$$

donde k es el índice de presentación patrón.

El coeficiente b en la Ecuación nº 12.21 la Ecuación nº 12.22 se llama el factor de impulso y determina la ponderación de las estimaciones instantáneas anteriores de la matriz de covarianza y correlación cruzada vector. El coeficiente b se ajusta usualmente en el rango de 0.9 a 0.99.

Paso 6. Actualizar el vector de pesos por cada neurona en la red de la siguiente manera.

En cada neurona calcula el vector gradiente de la función objetivo.

Ecuación nº 12.23

$$g_j^{(s)}(k) = C^{(s)}(k) \cdot w_j^{(s)} - p_i^{(s)}(k)$$

Si $g_j^{(s)}=0$ no actualizar el vector de pesos de la neurona y vaya al paso 7; en otro caso lleve a cabo los siguientes pasos:

(b) Encuentre la dirección $\mathbf{d}(k)$.

Si el número de iteración es un múltiplo entero del número de pesos en la neurona, a continuación,

Ecuación nº 12.24

$$d_j^{(s)}(k) = -g_j^{(s)}(k)$$

Esto se llama la función de reinicio del algoritmo. Después de un par de iteraciones, el algoritmo se reinicia por una búsqueda en la dirección de descenso más pronunciada. Esta característica de reinicio es importante para la convergencia global, ya que en general uno no puede garantizar que las direcciones $\mathbf{d}(k)$ generados sean direcciones descendentes.

Otra cuestión : calcular el vector de dirección mediante la adición del vector gradiente negativo de la función objetivo en una combinación lineal de los previos vectores de dirección:

Ecuación nº 12.25

$$d_j^{(s)}(k) = -g_j^{(s)}(k) + \beta_j^{(s)} \cdot d_j^{(s)}(k-1)$$

dónde

Ecuación nº 12.26

$$\beta_j^{(s)}(k) = -g_j^{(s)T}(k) \frac{C^s(k) \cdot d_j^{(s)}(k-1)}{d_j^{(s)T}(k-1) \cdot C^s(k) \cdot d_j^{(s)}(k-1)}$$

Las diversas versiones de gradientes conjugados se distinguen por la manera en que se calcula este parámetro β .

Calcular el tamaño del paso

Ecuación nº 12.27

$$\alpha_j^{(s)}(k) = \frac{g_j^{(s)T}(k) \cdot d_j^{(s)}(k)}{d_j^{(s)T}(k) \cdot C^s(k) \cdot d_j^{(s)}(k)}$$

Modificar el vector de pesos de acuerdo con

Ecuación nº 12.28

$$w_j^{(s)}(k) = w_j^{(s)}(k-1) + \alpha_j^{(s)}(k) \cdot d_j^{(s)}(k)$$

Paso 7. Hasta que la red alcanza un nivel predeterminado de precisión, regrese al paso 2.

12.4.5 El algoritmo de Broyden-Goldfarb-Shanno (BFGS)

Programa Matlab^c tomado de Sing P.

```
%
%
% Broydon - Fletcher - Goldfarb - Shanno (BFGS) Method
%
% An m-file for the BFGS Method
%*****
% requires:                UpperBound_nVar.m
%                          GoldSection_nVar.m
% and the problem m-file: Objectivefunction.m
%
%*****
%
% the following information are passed to the function
%
% the name of the function          'funcname'
% funcname.m : returns scalar for vector input
%
% the gradient calculation is in      gradfunction.m
% gradfunction.m: returns vector for vector input
%
% initial design vector              dvar0
% number of iterations                niter
%
%-----for golden section
% the tolerance (for golden section)  tol
%
%-----for upper bound calculation
% the initial value of stepsize        lowbound
% the incremental value                 intvl
% the number of scanning steps         ntrials
%
% the function returns the final design and the
```

objective function

```

% sample calling statement

% BFGS('Objectivefunction',[0.5 0.5],20, 0.0001, 0,1
,20)
%
function ReturnValue = BFGS(funcname, ...
    dvar0,niter,tol,lowbound,intvl,ntrials)

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%% management functions
clc % position the cursor at the top of the screen
clf % closes the figure window
format compact % avoid skipping a line when writing to
the command window
warning off % don't report any warnings like divide by
zero etc.
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%
fprintf('\nBFGS Method\n');
fprintf('The problem: '),disp(funcname)

% convergence/stopping criteria
e1 = 1.0e-04; e2 = 1.0e-08; e3 = 1.0e-04;
nvar = length(dvar0); % length of design vector or
number of variables
% obtained from start vector
if (nvar == 2)
    %*****
    % plotting contours -
    % only for two variables
    % previous generation code is left in place
    %*****
    % the plot is centered around initial guess
    % with (+-) delx1, delx2 on either side
    % this can be reset by user

    delx1 = 6;
    delx2 = 5;

    x1 = (dvar0(1)-delx1):0.1:(dvar0(1)+delx1);
    x2 = (dvar0(2)-delx2):0.1:(dvar0(2)+delx2);

    x1len = length(x1);
    x2len = length(x2);
    % [X1 X2] = meshgrid(x1,x2);

```

```

%      Vfuncname = strcat('V',funcname);
%      fun = feval(Vfuncname,X1,X2);
for i = 1:x1len;
    for j = 1:x2len;
        x1x2 =[x1(i) x2(j)];
        fun(j,i) = feval(funcname,x1x2);
    end
end

c1 = contour(x1,x2,fun, ...
    [3.1 3.25 3.5 4 6 10 15 20 25],'k');
%clabel(c1); % remove labelling for clarity

grid
xlabel('x_1');
ylabel('x_2');
funname = strrep(funcname,'_','-');
title(strcat('BFGS:',funname));

% note that contour values are problem dependent
% the range is problem dependent
%*****
% finished plotting contour
%*****

end
%*****
% Numerical Procedure
%*****
% design vector, alpha , and function value is stored
xs(1,:) = dvar0;
x = dvar0;
Lc = 'r';
fs(1) = feval(funcname,x); % value of function at
start
as(1)=0;
grad = (gradfunction(funcname,x)); % steepest descent

A = eye(nvar); % initial metric
% uses MATLAB built in identity matrix function

convg(1)=grad*grad';
for i = 1:niter-1
    % determine search direction
    fprintf('iteration number: '),disp(i)
    %s = (-A*grad)'; % s is used as a row vector
    s = (-inv(A)*grad)';

```

```

output = GoldSection_nVar(funcname,tol,x, ...
    s,lowbound,intvl,ntrials);

as(i+1) = output(1);
fs(i+1) = output(2);
for k = 1:nvar
    xs(i+1,k)=output(2+k);
    x(k)=output(2+k);
end
x
grad= (gradfunction(funcname,x)) % steepest
descent

convg(i+1)=grad*grad';
% print convergence value
fprintf('gradient length squared:
'),disp(convg(i+1));
fprintf('objective function value:
'),disp(fs(i+1));
%*****
% draw lines
%*****

if (nvar == 2)
    line([xs(i,1) xs(i+1,1)], [xs(i,2)
xs(i+1,2)], 'LineWidth', 2, ...
        'Color', Lc)
    itr = int2str(i);
    x1loc = 0.5*(xs(i,1)+xs(i+1,1));
    x2loc = 0.5*(xs(i,2)+xs(i+1,2));
    %text(x1loc,x2loc,itr);
    % writes iteration number on the line
    if strcmp(Lc,'r')
        Lc = 'k';
    else
        Lc = 'r';
    end

    pause(1)
    %*****
    % finished drawing lines
    %*****
end

if(convg(i+1)<= e3) break; end; % convergence
criteria
% update the metric here

```

```
delx = (x - xs(i,:))';
gradold = gradfunction(funcname,xs(i,:));
Y = (grad -gradold)'; % column vector
B = (Y*Y')/(Y'*delx);
C = gradold'*gradold/(gradold*s');
A = A + B + C;

%*****
% complete the other stopping criteria
%*****
end
len=length(as);
%for kk = 1:nvar
designvar=xs(length(as),:);
fprintf('The problem: '),disp(funcname)
fprintf('\nNo. of iterations: '),disp(len)
fprintf('\nThe design vector,function value \nduring
the iterations\n')
disp([xs fs']);
```

12.5 Algoritmos

12.5.1 Algoritmo memético

Algoritmo Memético General ⁶⁰

Entrada: una instancia I de un problema P .

Salida: una solución sol .

```

// generar población inicial
1 : para  $j \leftarrow 1:popsiz$  hacer
2 :   sea  $ind \leftarrow$  GenerarSoluciónHeurística ( $I$ )
3 :   sea  $pop[j] \leftarrow$  MejoraLocal ( $ind, I$ )
4 : finpara
5 : repetir // bucle generacional
   // Selección
6 :   sea  $criadores \leftarrow$  SeleccionarDePoblación ( $pop$ )
   // Reproducción segmentada
7 :   sea  $auxpop[j] \leftarrow pop$ 
8 :   para  $j \leftarrow 1:\#op$  hacer
9 :     sea  $auxpop[j] \leftarrow$  AplicarOperador ( $op[j], auxpop[j - 1], I$ )
10 :   finpara
11 :   sea  $newpop \leftarrow auxpop[\#op]$ 
   // Reemplazo
12 :   sea  $pop \leftarrow$  ActualizarPoblación ( $pop, newpop$ )
   // Comprobar convergencia
13 :   si Convergencia ( $pop$ ) entonces
14 :     sea  $pop \leftarrow$  RefrescarPoblación ( $pop, I$ )
15 :   fin
16 : hasta CriterioTerminación ( $pop, I$ )
17 : devolver Mejor ( $pop, I$ )

```

13 Índices y Referencias

13.1 Índice de Gráficas

Gráfica nº 1.1 Distribución radial de $Re(H_{jz})$	47
Gráfica nº 1.2 Distribución radial de $Re(E_{jf})$	48
Gráfica nº 1.3 $L(\delta)$ para distintos medios.....	48
Gráfica nº 1.4 $L(\omega)$ para distintos medios.....	49
Gráfica nº 1.5 Curva de magnetización del acero . Modelo de Frölich-Kennelly.....	61
Gráfica nº 5.1 Medidas de resistencia vs reactancia para distintos espesores de capas.	98
Gráfica nº 5.2 Medidas de resistencia vs reactancia para distintos espesores de capas	98
Gráfica nº 5.3 Medidas de resistencia vs reactancia para distintos espesores de capas	99
Gráfica nº 5.4 Medidas de resistencia vs reactancia para distintos espesores de capas a la frecuencia de 0,001 kHz	101
Gráfica nº 5.5 Medidas de resistencia vs reactancia para distintos espesores de capas a la frecuencia de 0,01 kHz	101
Gráfica nº 5.6 Medidas de resistencia vs reactancia para distintos espesores de capas a la frecuencia de 0,1 kHz	102
Gráfica nº 5.7 Medidas de resistencia vs reactancia para distintos espesores de capas a la frecuencia de 1 kHz	102
Gráfica nº 5.8 Medidas de resistencia vs reactancia para distintos espesores de capas a la frecuencia de 10 kHz	103
Gráfica nº 5.9 Medidas de resistencia vs reactancia para distintos espesores de capas a la frecuencia de 100 kHz	103
Gráfica nº 5.10 Medidas de resistencia vs reactancia para distintos espesores de capas a la frecuencia de 100 kHz	104
Gráfica nº 5.11 Medidas de resistencia vs reactancia para distintos espesores de capas a la frecuencia de 1000 kHz	104
Gráfica nº 5.12 Contorno para los límites de control	106
Gráfica nº 5.13 Ejemplo de placa fuera de límites.....	106
Gráfica nº 6.1 Distribución de medidas.....	110
Gráfica nº 6.2 Distribución estadística de medidas.....	112
Gráfica nº 6.3 Contraste con la distribución normal.....	113

Gráfica nº 6.4 Comparación distribución normal acumulada	114
Gráfica nº 6.5 Trazado cuantil – cuantil	115
Gráfica nº 6.6 Divergencia con la distribución normal	115
Gráfica nº 6.7 Divergencia con la distribución normal	116
Gráfica nº 6.8 Contraste entre métodos de medidas ópticos	116
Gráfica nº 6.9 Distribución normal medidas eléctrica	118
Gráfica nº 6.10 Medidas de L_s en probetas y placas	118
Gráfica nº 6.11 Correlación lineal ambos métodos.....	119
Gráfica nº 7.1 $\Delta R(f)$ Regresión polinomial para la curva de resistencia	124
Gráfica nº 7.2 Regresión polinomial para la curva de reactancia	124
Gráfica nº 7.3 Comparación entre los valores de h de referencia y los calculados por la curva de regresión	125
Gráfica nº 7.4 Resolución del problema inverso	126

13.2 Índice de Figuras

Figura nº 1.1 Campos en la proximidad de la superficie de un buen conductor.....	35
Figura nº 1.2 Variación de la impedancia normalizada con el espesor de la capa (<i>clad</i>).	41
Figura nº 1.3 Variación de los valores experimentales y calculados de la impedancia normalizada con la frecuencia y el entrehierro (<i>liftoff</i>).	41
Figura nº 1.4 Corrientes inducidas en una placa de espesor finito.....	42
Figura nº 1.5 Frecuencia de resonancia	50
Figura nº 1.6 Resistencia vs. Frecuencia.	51
Figura nº 1.7 Distribución líneas de flujo (detalle)	52
Figura nº 1.8 Mallado 2D.	53
Figura nº 1.9 J_t	54
Figura nº 1.10 Mallado 3D	54
Figura nº 1.11 B_s	54
Figura nº 1.12 Autoinducción L vs. β	56
Figura nº 1.13 Defasaje Θ vs. Frecuencia.	57
Figura nº 1.14 Curvas de histéresis para distintas aleaciones de hierro.	58
Figura nº 1.15 Curvas magnéticas de Rayleigh.....	59
Figura nº 2.1 Objetivos y plan de trabajo.....	65
Figura nº 2.2 Equipo Defectoscop F140d.	66
Figura nº 2.3 Multímetro digital hp 34401A $6^{1/2}$	67
Figura nº 2.4 Montaje y conexiones equipo Defestoscop F140d.....	67
Figura nº 2.5 Equipo Agilent hp 4294A.	68
Figura nº 2.6 Ejemplo de precisión en la medida indicado en la carta de reactancias. .	69
Figura nº 2.7 Montaje y conexiones equipo de medida HP 4294A.....	69
Figura nº 2.8 Sonda diferencial.....	70
Figura nº 2.9 Distintos tipos de bobinas sonda.....	71
Figura nº 2.10 Conector USB/GPIB enlace del impedancímetro al ordenador para adquisición de datos	72
Figura nº 3.1 Modelo de prueba de corrientes inducidas sobre una placa de acero, en blanco zona de integración	76
Figura nº 4.1 Líneas de campo a 50Hz.	85
Figura nº 4.2 Líneas de campo a 50 kHz.....	85

Figura nº 4.3 Az 50 Hz.....	85
Figura nº 4.4 Az 50 kHz.	85
Figura nº 4.5 Dimensionado capas de protección.	85
Figura nº 4.6 J_t 50 Hz (vectorial).....	85
Figura nº 4.7 J_t 50 kHz (vectorial).	85
Figura nº 4.8 Elemento SOLID236.	86
Figura nº 4.9 Mallado 3D hexaédrico.....	87
Figura nº 4.10 Volumen elemento entorno	87
Figura nº 4.11 Detalle entorno bobina placa.....	88
Figura nº 4.12 Distribución de la Inducción,	88
Figura nº 4.13 Campo magnético vectorial.....	89
Figura nº 4.14 Densidad de corriente.	89
Figura nº 4.15 Densidad de corriente (vectorial).	90
Figura nº 4.16 Distribución de J_t superficial a la placa.....	90
Figura nº 4.17 Distribución transversal 2D líneas de fuerza magnética.	91
Figura nº 5.1 Representación de un modelo cuadripolar.....	95
Figura nº 5.2 Cadena de conexión de los cuadripolos.	95
Figura nº 6.1 Fotos de perfiles y del patrón de medida.	111
Figura nº 6.2 Conjunto de probetas X.....	112
Figura nº 8.1 Una neurona biologica.	133
Figura nº 8.2 Representación esquemática de dos neuronas artificiales y sus procesos internos [Rumelhart, Hinton y McClelland, [39].....	136
Figura nº 8.3 Un ejemplo de una RNA de tres capas, mostrando neuronas dispuestas en capas.	137
Figura nº 8.4 Ejemplo de pesos de la red y la matriz de pesos que la acompaña [Hecht-Nielsen,[].....	138
Figura nº 8.5 Función lineal	141
Figura nº 8.6 Función escalón	141
Figura nº 8.7 Función rampa	141
Figura nº 8.8 Función de Gauss	141
Figura nº 8.9 Función sigmoide binaria	141
Figura nº 8.10 Función sigmoide tangente hiperbólica.....	141
Figura nº 8.11 Ejemplo de una red de alimentación directa de dos capas.....	144

Figura nº 8.12 Ejemplo de una superficie de error anterior a un espacio de peso de dos dimensiones.....	145
Figura nº 8.13 Estructura general para la función de mapeado de las RNAs.	150
Figura nº 8.14 Clasificación de modelos de RNAs con respecto al tiempo de integración.	154
Figura nº 8.15 Neurona Básica TDNN con n conexiones de unidades de entrada y retrasos en p cada señal de entrada (k es el índice de tiempo discreto) [].....	156
Figura nº 8.16 Filtro neurona no lineal [45].....	157
Figura nº 8.17 La arquitectura neural SRN (donde z-1 es un retraso unidad de tiempo) [45].....	157
Figura nº 8.18 El método de varios pasos recursiva. Nuevas salidas estimadas se desplazan a través del vector de entrada y las entradas antiguas se descartan. Todas las redes neuronales son idénticas. [46].....	158
Figura nº 8.19. Las cadenas de RNAs: comenzando con una clásica de un predictor de un paso por delante, la salidas se insertan en siguiente predictor de una sola etapa, mediante la adición de la predicción de un solo paso por delante para el vector de entrada del predictor subsiguiente. [46].....	159
Figura nº 8.20 Método multipaso directo. La RNA que se utiliza es a menudo una red temporal de algún tipo.	160
Figura nº 8.21 Una red con sobre entrenamiento tiende a seguir los ejemplos de entrenamiento y por lo tanto pierde su capacidad de generalizar (aproximación a función sinusoidal). [].....	165
Figura nº 8.22 Eligiendo el número adecuado de ciclos de aprendizaje [41]	166
Figura nº 9.1 Estructura general de un algoritmo genético AG.	173
Figura nº 9.2 Comparación entre el método convencional y el planteamiento con algoritmo genético.....	175
Figura nº 9.3 La estructura general de los algoritmos genéticos híbridos.	187
Figura nº 9.4 La aplicación de una técnica de búsqueda local para un bucle del AG .	189
Figura nº 9.5 Esquema de la variación de población de dientes de sierra AG.....	194
Figura nº 9.6 Función de pertenencia para p_M (izq.) y para p_C (der.).....	197
Figura nº 9.7 El concepto de soluciones óptimas de Pareto (caso de maximización). 200	
Figura nº 9.8 Región factible y soluciones eficientes espacio de decisión S y en espacio de criterio Z.....	201
Figura nº 9.9 Ilustración de la selección veGA.	204
Figura nº 9.10 Objetivos en el espacio de decisión S y el criterio de espacio Z.....	204
Figura nº 9.11 Población en diferentes generaciones obtenidas utilizando veGa.....	205
Figura nº 9.12 Ilustración de la clasificación de Goldberg (caso de minimización). ...	206

Figura nº 9.13 Ilustración de clasificación moGA (caso de minimización).....	206
Figura nº 9.14 Ilustración de NSGA rango (caso de minimización).....	207
Figura nº 9.15 Ilustración de búsqueda de dirección fija y múltiple en el espacio criterio (caso de minimización).	208
Figura nº 9.16 Ilustración de spEA (caso de maximización).....	209
Figura nº 9.17 Pesos adaptativos y hiperplano adaptativo (caso de maximización) ...	210
Figura nº 9.18 Ilustración de una nsGA II (caso de minimización)	213
Figura nº 9.19 Ejemplo de valores de aptitud para diferentes mecanismos de asignación de aptitud. (caso de maximización)	214
Figura nº 10.1 Ventana generación red neuronal	219
Figura nº 10.2 Red neural constituida.....	220
Figura nº 10.3 Controles	220
Figura nº 10.4 Ciclos de apredizaje	221
Figura nº 10.5 Tabla de errores.	222
Figura nº 10.6 Tabla de errores.	222
Figura nº 10.7 Tabla de errores.	222
Figura nº 12.1 PLANE53.....	232
Figura nº 12.2 Calibrado del equipo Defectoscop	251
Figura nº 12.3 Ejemplo de una red MLP feedforward con tres capas.	259

13.3 Índice de Tablas

Tabla nº 1.1 Resultados obtenidos sobre la búsqueda con palabras clave.	28
Tabla nº 1.2 Profundidad de penetración de los campos electromagnéticos para distintos materiales a distintas frecuencias.....	36
Tabla nº 1.3 Curva de magnetización	44
Tabla nº 1.4 Pérdidas volumetricas de potencia eléctrica.	44
Tabla nº 1.5 Materiales de las probetas	51
Tabla nº 1.6 Características de las muestras	55
Tabla nº 1.7 Valores medidos para las distintas muestras	55
Tabla nº 1.8 Comparativa entre vslores medidos y teóricos.....	56
Tabla nº 3.1 Impedancia vs. Frecuencia.....	79
Tabla nº 3.2 Variación de la Impedancia vs frecuencia	80
Tabla nº 4.1 Características de los materiales	84
Tabla nº 4.2 Resultados pérdidas de potencia modelo ANSYS	92
Tabla nº 4.3 Cálculo comparativo de pérdidas	92
Tabla nº 5.1 Características eléctricas y magnéticas de los materiales	96
Tabla nº 5.2 Equivalencia entre el modelo de cuadripolos y la capa de metal.....	96
Tabla nº 5.3 Espesores de las placas.....	105
Tabla nº 6.1 Tablas de estadística de valores	113
Tabla nº 6.2 Valore medidos y comparados entre ambos métodos	117
Tabla nº 8.1 Resumen de las técnicas de aprendizaje supervisado	143
Tabla nº 8.2 Resumen de las técnicas de aprendizaje no supervisado	143
Tabla nº 8.3 Detalle del rendimiento de las RNAs en algunos de sus aspectos []	162
Tabla nº 9.1 Explicación de los términos AG.....	176
Tabla nº 12.1 Ejemplo.....	252
Tabla nº 12.2.....	253
Tabla nº 12.3.....	254
Tabla nº 12.4.....	255

13.4 Referencias bibliográficas

-
- ¹ **Galileo Galilei**. Diálogo sobre los dos máximos sistemas del mundo ptolemaico y copernicano. Alianza Editorial, Edic Beltrán, A. Madrid 1994
- ² **Sambursky, S.** El mundo físico de los griegos. Alianza Universidad, Vers. Pascual M.J. Madrid 1990
- ³ **Elliot R.S.** Electromagnetics: History, theory, and applications. Oxford University IEEE Press 1993
- ⁴ **Sambursky, S.** El mundo físico a finales de la antigüedad. Alianza Universidad. Vers. Solís, C. Madrid 1990
- ⁵ **Lorrain, P y Corson, D.R.** Campos y ondas electromagnéticos. Edic. Selecciones Científicas Trad. J.A. Vallés Abarca Madrid 1972
- ⁶ **Fournet, G.** Électromagnétisme á partir des équations locales. Ed. Masson Paris 1979
- ⁷ **Jackson, J.D.** Electrodinámica clásica Alhambra Universidad 2ª Edic. Trad. G. Barral Madrid 1980
- ⁸ **Chipman, R.A.** Teoría y problemas líneas de transmisión Trad. Martínez C. 89-93 MacGraw-Hill
- ⁹ **Dodd C.V. Deeds W.E.** Analytical Solutions to Eddy-Current Probe Coils Problem Journal Applied Physics. Vol. 39 6 2829-2838 May 1968
- ¹⁰ **Dodd C.V. Deeds W.E.** Calculation of Magnetic Fields from Time Varying Currents in the presence of Conductors Oak Ridge National Laboratory July 1975
- ¹¹ **Blitz J.** "Electrical and magnetic method of nondestructive testing". 90-99 Chapman & Hall 2º Ed. 1991
- ¹² **Jiles D.C.** Magnetic properties and microstructure of AISI 1000 series carbon steels J. Phys. D : Appl. Phys 21 (1988) 1186-1195
- ¹³ **Epelboin I.** Délimitation du domaine de Rayleigh dans les Champs alternatifs à la lumière de récente travaux théoriques et expérimentaux J. Phys. Radium 12 (3) pp 361-371 (1951)
- ¹⁴ **Néel L.** La loi d'approche en α : H et une nouvelle théorie de la dureté magnétique Le Journal de la Physique et le Radium série VIII tome IX pp 184-192 1948
- ¹⁵ **Becker R & Döring W.** Ferromagnetismus Springer Berlin 1938
- ¹⁶ **Jiles D.** Introduction to Magnetism and magnetic materials 2ª Ed Chapman & Hall/CRC 1998
- ¹⁷ **Dodd C.V. and Deeds, V.E.** Analytical solutions to eddy-current probe coil problems. Oak Ridge National Laboratory. Nov. 1967
- ¹⁸ **Theodoulidis T.** Series expansions in eddy current non-destructive evaluations models. Journal of materials Processing Technology 161 (2005) 343-347
- ¹⁹ **Cheng C.C., Dodd C.V., Deeds V.E.** General analysis of probe coils near stratified conductors. International Journal of Nondestructive testing, 1971, Vol nº8, 109-108
- ²⁰ **Abramowitz and Stegun** Handbook of Mathematical Functions National Bureau of standard Washington 1970
- ²¹ **Brezinski, C** Convergence Acceleration... J. Comp Appl. Math, 12, 1-21, 2000

-
- ²² **Tarantola. A.** **Inverse Problem Theory and Methods for Model Parameter Estimation** Society for Industrial and Applied Mathematics, Philadelphia, 2005
- ²³ **Moaveni Saeed**, Finite element analysis 2^aed Pearson Education New Jersey 2003
- ²⁴ **ANSYS** Training Manual Low frequency electromagnetic Jun,2004
- ²⁵ **Chipman,R.A.** Teoría y problemas líneas de transmisión Trad. Martínez C. MacGraw-Hill
- ²⁶ **Norton S.J. and Bowler J.R.** Theory of eddy current inversion, J. Appl. Phys. 73, 501, 1993
- ²⁷ **Norton S.J. and Boewler J.R.** Eddy current interaction with an ideal crack II J. Appl. Phys. 75,8138, 1994
- ²⁸ **Turing A.M.** On computable numbers, with an application to the ENTSCHEIDUNG - SPROBLEM London Mathematical Society Nov. 12 230-265 1936
- ²⁹ **Rosenblatt F.** The perceptron : A probabilistic model for information storage and organization in brain. Psychological Review, Vol 65(6) Nov 1958, 386-408
- ³⁰ **McCulloch W.S. and Pitts W.** A logical calculus of the ideas immanent in nervous activity Bulletin of Mathematical Biophysics 5:115-1333 1943
- ³¹ **Moor J.** The Dartmouth College Artificial Intelligence Conference: The Next Fifty Years AI Magazine 27 Number 4 (2006)
- ³² **Rumelhart D.V. Hinton G.E. & Williams R.J.** Learning representations by back-propagation errors. Nature , Vol 323.Issue 6088, pp553-536 (1986)
- ³³ **Ayad, A. Benhamida F.** Solution of Inverse Problems in Electromagnetic NDT Using Neural Networks PRZEGLAD ELECTROTECHNICZNY (Electrical review) 330-333 R 87 NR9a /2011
- ³⁴ **Hecht-Nielsen R.** Theory of the Back propagation Neural Network Neural Network IJCNMN 593-605 Jun 1989 Publisher IEEE
- ³⁵ **Block H.D.** A Review of “ Perceptrons : An Introduction to Computational Geometry” by Marvin Minsky and Seymour Papert . Information and control 17,501-522 (1970)
- ³⁶ **Minsky M. Papert S.** An introduction to Computational Geometry. M.I.T. Press, Mass., 1969I
- ³⁷ **Kohonen T.** Self-Organization and Associative Memory Ed 2 Springer-Verlag Berlin 1984
- ³⁸ **Hopfield J.J.** Neural networks and physical systems with emergent collective computational abilities. Proceeding of the National Academy of USA Vol. 79N° 8 Part 1 Biological Sciences 2554-2558 Apr. 1982.
- ³⁹ **Rumelhart, McClelland, J. L D. E., and the PDP Research Group.** Parallel distributed processing: Explorations in the microstructure of cognition. Vol.1 Foundations . Cambridge, MA: MIT Press. (1986)
- ⁴⁰ **Dhar V. Und Stein R.** Intelligent Decision Support Method: The Science of Knowledge Work Upper Saddle River ,NJ, Prentice Hall 1997
- ⁴¹ **Hecht-Nielsen R.** Neurocomputing. Reading, Mass. Etc. Addison-Wesley 1990
- ⁴² **Fahlman S.E.** An empirical study of learning speed in back-propagation network . Computer Science Department. Carnegie Mellon University Pittsburgh, Pennsylvania June 1988
- ⁴³ **Fahlman S.E and Lebiere C.** The cascade-correlation learning structure Computer Science Department. Carnegie Mellon University Pittsburgh, Pennsylvania June 1988

-
- ⁴⁴ **Chen S. Cowan C.F.N Grant P.M.** Orthogonal least squares learning algorithm for radial basis function network. Neural Network, IEEE Transactions on Vol 2 302-309 Mar 1991
- ⁴⁵ **Ham F.C. Kostanic I** Principles of Neurocomputing for Science and Engineering McGraw Hill 2001
- ⁴⁶ **Duhous M Suykens J de Moor B Vandewalle J** Improved long-term temperature prediction by chaining of neural networks. International Journal of Neural Systems Vol11, No. 1 1-10 2001
- ⁴⁷ **Boné R. Cruciano** Multi-step-ahead Prediction with Neural Networks: a Review RFAI 9º Approches Connexionnistes en Sciences Économiques et en Gestion pp.97-106 nov 2020
- ⁴⁸ **Zealand C.M. Burn D.H. Simonovic S.P.** Short term stream forecasting using neural networks Journal of Hydrology Vol. 214 32-48 (1999)
- ⁴⁹ **Dhar V. Stein R.** Seven Methods for transforming corporation data Business Intelligence 1st. ed. Prentice Hall Dec 1996
- ⁵⁰ **Beale M.H: Hagan M.T. Demuth H.B.** Neural Network Toolbox™ User guide MATLAB® The MathWorks inc. 2015
- ⁵¹ **Holland, J.** Genetic Algorithms Scientific American 66-72 jul 1992
- ⁵² **Fogel L.J.** Artificial Intelligence through Simulated Evolution New York John Wiley & Sons. 1966
- ⁵³ **Koza J.R.** Genetic programming Bradford book, Cambridge MIT press
- ⁵⁴ **Goldberg D.E.** Genetic Algorithms in Search, Optimization and Machine Learning, Addison-Wesley, 1989
- ⁵⁵ **Budin L Golub M. Budin A.** Traditional Techniques of Genetic Algorithms Applied to Floating Point Chromosome Representation Faculty of Electrical Engineering and Computing. Dept. Electronic, Microelectronics, Computer and Intelligent Systems. Zagreb
- ⁵⁶ **Michalewicz** Genetic Algorithms + Data Structures =Evolution Programs
- ⁵⁷ **Holland J.H.** Adaptation in natural and artificial systems. University of Michigan Press 2007
- ⁵⁸ **Grefenstette J.J.** Lamarckian Learning in Multi-agent Environments Proceedings 4th International Conference on Genetic Algorithms : Univ. California, San Diego, July 13-16 1991
- ⁵⁹ **Moscato P. Norman M.G. A** “ Memetic” Approach for Traveling Salesman Problem Implementation of a Computational Ecology for Combinational Optimization on Message-Passing Systems Parallel computing and transcomputer application
- ⁶⁰ **Cotta** Una visión General de los Algoritmos Meméticos 1ª Ed. Procedimientos Metaheurístico en Economía y Empresa, ASEPUMApp139-136 2007