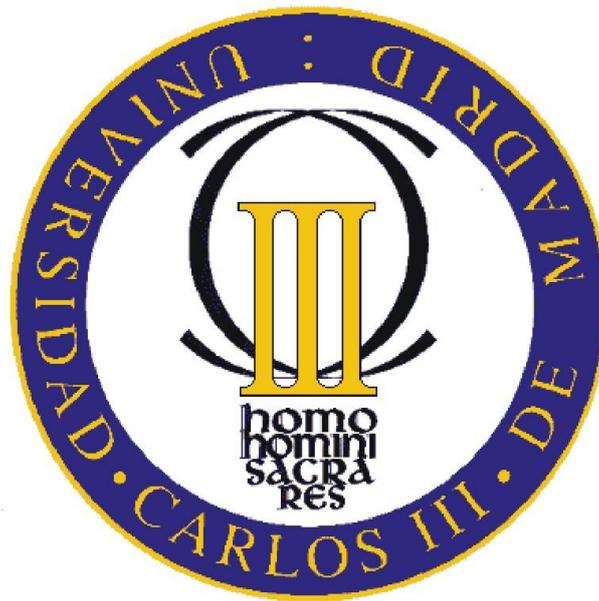


UNIVERSIDAD CARLOS III DE MADRID

ESCUELA POLITÉCNICA SUPERIOR

DEPARTAMENTO DE INGENIERÍA MECÁNICA



***Análisis de sistemas de clasificación de defectos en ejes***

Ingeniería Industrial: Máquinas y Estructuras

Autor: Alberto Adrados Somolinos

Tutor: Cristina Castejón Sisamón



## AGRADECIMIENTOS

Quiero agradecer a mi familia todos los esfuerzos y apoyos ofrecidos para poder terminar mis estudios universitarios así como la paciencia que han tenido en determinados momentos, especialmente en época de exámenes.

Del mismo modo, tengo que recordar a mis amigos, especialmente a aquellos compañeros de estudios con los que he pasado muchas horas de estudio pero también buenos ratos que permiten desconectar de la universidad por momentos

Asimismo, tengo que dar las gracias a Alberto Ordoñez por su dedicación en este proyecto junto por las horas destinadas a atenderme y orientarme en este proyecto. También quiero desearle suerte en su nuevo trabajo.

Igualmente tengo que agradecer a Cristina Castejón por las molestias ocasionadas al hacerse cargo de este proyecto.

Por último, quiero dar las gracias a todos aquellos a los que, en algún momento, me han ayudado durante el desarrollo de este proyecto.



## RESUMEN

El mantenimiento está cobrando cada vez más importancia en la industria actual por las consecuencias económicas de ahorro que conlleva una correcta elección y ejecución del tipo de mantenimiento. Por esta razón se emplean, cada día más, sistemas de seguimiento de procesos que permiten realizar un seguimiento de las máquinas sin necesidad de parar la actividad para comprobar el estado de la maquinaria.

Este tipo de sistemas generalmente hacen un seguimiento de los elementos con mayor facilidad para presentar problemas y cuyo fallo tenga gran repercusión en el proceso. Un componente de vital importancia para el correcto funcionamiento de cualquier máquina son los ejes, los cuales pueden provocar graves daños en el conjunto en el que se encuentra montado o en elementos de su entorno.

Los ejes pueden presentar fisuras debido a las condiciones de operación dentro del proceso. La aparición de un nuevo método para analizar las señales temporales denominado descomposición wavelet ha hecho que se pueda detectar la presencia de fisuras mediante su estudio, algo que con la Transformada de Fourier resulta difícil de llevar a cabo.

Además, el desarrollo de redes neuronales artificiales ha posibilitado la implantación de sistemas de seguimiento sin necesidad de depender de factores humanos. Estas redes permiten identificar el estado del eje dentro de unas clases previamente definidas según las señales procedentes del sensor colocado en la máquina e introducidas como inputs, tomando el operario decisiones basadas en los resultados mostrados por las redes neuronales.

En el presente proyecto se ha procedido a ensayar tres tipos de ejes, uno de ellos en estado óptimo y otros dos con fisuras perpendiculares a su eje, y adquirir las vibraciones sufridas durante el ensayo para estudiar posteriormente el comportamiento de tres redes neuronales que permiten clasificar las señales adquiridas según el tipo de eje al que correspondan. Previamente a la clasificación de las señales hay que realizar un análisis wavelet de las señales que será el que proporcione los inputs de las redes neuronales.

**Palabras clave:** *wavelet, Fourier, wavelet packet, redes neuronales, ejes fisurados, MATLAB®, Rotokit, velocidad crítica.*

**ABSTRACT**

Maintenance is becoming more and more important for current industry due to economic of savings that it entails a correct election and execution of the maintenance type. For this reason, monitoring systems that make possible to do a machine monitoring without the need of stopping the activity to checking the machine state are actually used more and more.

Generally, this kind of systems makes a monitoring of the elements with a greater facility to having problems and whose failure has a big repercussion in the process. Shafts are components of vital importance for the correct operation of any machine which can cause serious damages to the system where they are assembled or to surroundings elements.

Shafts can present cracks due to operation conditions in the process. The appearance of a new method to analyze signal temporary, called wavelet decomposition, has done that presence of cracks can be detected by its study, something that, with Fourier Transform, results difficult to carry out.

Furthermore, neuronal network development has made possible the introduction of monitoring systems without need to depend on human factors. These networks enable to identify the shaft state within some pre-established kinds according to the signals from the sensor put in the machine and introduced as inputs, taking the operator decisions based on results showed by neural networks.

In the present project, three shafts have been tested, one of them in an optimum state and the other two with a crack perpendicular to their axe. Vibrations suffered during the test have been acquired in order to study later the performance of three kind of neural networks that allow classify the acquired signals according to the shaft type. Before the signal classification, it is necessary to make a wavelet analysis to the signals that provide the inputs to the neural networks.

**Keywords:** *wavelet, Fourier, wavelet packet, neural networks, cracked shafts, MATLAB®, Rotokit, critical speed.*

**TABLA DE CONTENIDO**

RESUMEN .....	ii
<b>CAPÍTULO 1: INTRODUCCIÓN .....</b>	<b>1</b>
1. INTRODUCCIÓN .....	2
1.1 ANTECEDENTES .....	2
1.2 OBJETIVOS DEL PROYECTO .....	5
1.3 ESTRUCTURA DEL DOCUMENTO .....	6
<b>CAPÍTULO 2: CONTEXTO TEÓRICO .....</b>	<b>7</b>
2. CONTEXTO TEÓRICO.....	8
2.1 INTRODUCCIÓN .....	8
2.2 DESCOMPOSICIÓN WAVELET .....	9
2.2.1 INTRODUCCIÓN .....	9
2.2.2 HISTORIA DE LAS WAVELET .....	9
2.2.3 TRANSFORMADA WAVELET CONTINUA .....	10
2.2.4 LAS WAVELETS Y LAS FUNCIONES SENOIDALES.....	11
2.2.5 TRANSFORMADA WAVELET DISCRETA .....	15
2.2.6 DESCOMPOSICIÓN WAVELET PACKET .....	17
2.3 REDES NEURONALES .....	20
2.3.1 INTRODUCCIÓN .....	20
2.3.2 HISTORIA DE LAS REDES NEURONALES.....	21
2.3.3 EL MODELO BIOLÓGICO .....	23
2.3.7 VENTAJAS DE LAS REDES NEURONALES.....	29
2.3.8 REDES NEURONALES EMPLEADAS .....	30
2.3.8.1 Redes neuronales de reconocimiento de patrones .....	30
2.3.8.2 Redes neuronales de función de base radial (RBF) .....	32
2.3.8.3 Redes neuronales probabilísticas (PNN).....	35
<b>CAPÍTULO 3: DESCRIPCIÓN DEL SISTEMA EXPERIMENTAL .....</b>	<b>38</b>
3. DESCRIPCIÓN DEL SISTEMA EXPERIMENTAL .....	39
3.1 MÁQUINA DE ENSAYOS.....	40
3.1.1 INTRODUCCIÓN .....	40
3.1.2 MOTOR.....	41



## TABLA DE CONTENIDO

v

3.1.3 VARIADOR DE FRECUENCIA .....	42
3.1.4 SEGURIDAD.....	43
3.2 CADENA DE MEDIDA .....	44
3.2.1 ACELERÓMETRO .....	44
3.2.1.1 Introducción .....	44
3.2.1.2 Tipos de acelerómetros .....	46
3.2.1.3 Acelerómetro MMF .....	47
3.2.2 FILTROS MMF .....	50
3.2.2.1 Introducción .....	50
3.2.2.2 Características .....	52
3.2.3 TARJETA DE ADQUISICIÓN DE DATOS KEITHLEY .....	54
3.2.3.1 Introducción .....	54
3.2.3.2 Entradas analógicas .....	56
<b>CAPÍTULO 4: SOFTWARE.....</b>	<b>57</b>
4. SOFTWARE .....	58
4.1 TESTPOINT™ .....	58
4.2 MATLAB® .....	60
4.2.1 INTRODUCCIÓN .....	60
4.2.2 NEURAL NETWORK TOOLBOX DE MATLAB® .....	62
4.2.2.1 Introducción .....	62
4.2.2.2 Arquitecturas de redes .....	64
4.2.2.3 Funciones de entrenamiento y aprendizaje .....	65
4.2.2.4 Soporte Simulink y aplicaciones de sistemas de control.....	65
4.2.2.5 Funciones de preprocesado y postprocesado .....	66
<b>CAPÍTULO 5: DESARROLLO DEL PROYECTO.....</b>	<b>67</b>
5. DESARROLLO DEL PROYECTO .....	68
5.1 DESCRIPCIÓN DE LOS ENSAYOS .....	68
5.2 TRATAMIENTO DE LAS SEÑALES .....	72
<b>CAPÍTULO 6: RESULTADOS EXPERIMENTALES .....</b>	<b>75</b>
6. INTRODUCCIÓN .....	76
6.1 RESULTADOS PREVIOS.....	76



## TABLA DE CONTENIDO

vi

6.2 OBTENCIÓN DE LOS PAQUETES DE ENERGÍA ÓPTIMOS .....	82
6.3 RESULTADOS DEL PROCESO DE CLASIFICACIÓN .....	85
6.3.1 RED PROBABILÍSTICA .....	85
6.3.1.1 Red probabilística incluyendo los paquetes 1 y 6 .....	85
6.3.1.2 Red probabilística sin incluir los paquetes 1 y 6 .....	93
6.3 RED DE BASE RADIAL .....	100
6.4 RED DE RECONOCIMIENTO DE PATRONES .....	102
6.4.1 Red de reconocimiento de patrones incluyendo los paquetes 1 y 6 .....	102
6.4.2 Red de reconocimiento de patrones excluyendo los paquetes 1 y 6 .....	110
6.5 PRESUPUESTO .....	117
<b>CAPÍTULO 7: CONCLUSIONES Y PROPUESTAS DE MEJORA .....</b>	<b>119</b>
7. CONCLUSIONES Y MEJORAS .....	120
7.1 CONCLUSIONES .....	120
7.2 PROPUESTAS DE MEJORA .....	123
<b>CAPÍTULO 8: BIBLIOGRAFÍA .....</b>	<b>125</b>
<b>CAPÍTULO 9: ANEXOS .....</b>	<b>129</b>
Anexo A: Rotokit .....	130
Anexo B: Resultados de la red de base radial .....	134



## ÍNDICE DE FIGURAS

Figura 2.1: Esquema de proceso de monitorización y diagnóstico. ....	8
Figura 2.2: Esquema tradicional de la monitorización de procesos industriales. ....	8
Figura 2.3: Descomposición de una señal en ondas. ....	12
Figura 2.4: Wavelets madre típicas. ....	13
Figura 2.5: Representaciones espectrales para el análisis de Fourier y el análisis wavelet. ....	14
Figura 2.6: Árbol de descomposición wavelet simple de tres niveles.....	18
Figura 2.7: Árbol de descomposición wavelet completo de tres niveles.....	19
Figura 2.8: Neurona biológica. ....	23
Figura 2.9: Comparación entre una neurona biológica (izda.) y una artificial (dcha.) . ....	23
Figura 2.10: Ejemplo de una red neuronal totalmente conectada. ....	24
Figura 2.11: Ejemplo de red feed-forward multicapa.....	31
Figura 2.12: Representación de una función de base radial.....	34
Figura 2.13: Modelo neuronal RBF.....	34
Figura 2.14: Topología de un modelo neuronal PNN.....	37
Figura 3.1: Esquema de las conexiones entre los aparatos de medida. ....	39
Figura 3.2: Imagen de la máquina de ensayos Rotokit. ....	40
Figura 3.3: Motor MARATHON 56T34F5301 J. ....	41
Figura 3.4: Variador de frecuencia Delta VFD 007S21B.....	42
Figura 3.5: Esquema de un sistema mecánico simple en el que se basa el funcionamiento de los acelerómetros. ....	44
Figura 3.6: Esquema con los diferentes elementos de los que consta un acelerómetro.....	45
Figura 3.7: Acelerómetro MMF KS943B.10. ....	47
Figura 3.8: Miniconector M5 del acelerómetro MMF KS943B.10. ....	48
Figura 3.9: Diseño a esfuerzo cortante del acelerómetro MMF KS943B.10. ....	48
Figura 3.10: Respuesta de amplitud típica (eje Z). ....	50
Figura 3.11: Módulo MMF M32. ....	51
Figura 3.12: Diagrama funcional y principio IEPE del M32. ....	51
Figura 3.13: Rango dinámico de los sensores IEPE.....	52
Figura 4.1: Pantalla del programa TestPoint™.....	58
Figura 4.2: Red neuronal de tres capas convertida en bloques Simulink®. ....	66
Figura 5.1: Rampa de ensayo realizada. ....	68
Figura 5.2: Orientación de los ejes en el sistema. ....	69
Figura 5.3: Disco empleado para el ensayo. ....	70
Figura 5.4: Imagen de los tres ejes ensayados. ....	71
Figura 5.5: Diagrama de flujo del proceso de tratamiento de señales. ....	72
Figura 5.6: Descomposición wavelet obtenida con el programa 1. ....	73
Figura 5.7: Aceleraciones medidas para el eje X correspondiente a cada tipo de eje. ....	73
Figura 6.1: Aceleraciones medidas para el eje X correspondientes a cada tipo de eje.....	77
Figura 6.2: Aceleraciones medidas para el eje Y correspondientes a los ejes ensayados.....	77
Figura 6.3: Aceleraciones medidas para el eje Z correspondientes a los ejes ensayados.....	78
Figura 6.4: Señales de aceleración según el eje X para un eje con una fisura del 12.5 %. ....	79
Figura 6.5: Señales de aceleración según el eje Y para un eje sano con una fisura del 12.5 %...79	79
Figura 6.6: Señales de aceleración según el eje Z para un eje sano con una fisura del 12.5 %...80	80



Figura 6.7: Descomposición wavelet de 8 niveles. ....	81
Figura 6.8: FFT de una de las señales adquiridas. ....	81
Figura 6.9: Gráfico de clasificación de una red probabilística para el eje X (c.p.). ....	87
Figura 6.10: Gráfico de la eficiencia de clasificación según el eje X de una red probabilística (c.p.). ....	87
Figura 6.11: Gráfico de clasificación de una red probabilística según el eje Y (c.p.). ....	89
Figura 6.12: Evolución de la clasificación del eje Y para una red probabilística (c.p.). ....	89
Figura 6.13: Gráfico de clasificación para el eje Z de una red probabilística (c.p.). ....	91
Figura 6.14: Eficiencia de la clasificación según el eje Z de una red probabilística (c.p.). ....	91
Figura 6.15: Gráfico de clasificación de una red probabilística según el eje X (s.p.). ....	94
Figura 6.16: Gráfico de la eficiencia de clasificación según el eje X de una red probabilística (s.p.). ....	94
Figura 6.17: Gráfico de clasificación para el eje Y de una red probabilística (s.p.). ....	96
Figura 6.18: Eficiencia de la clasificación según el eje Y de una red probabilística (s.p.). ....	96
Figura 6.19: Gráfico de clasificación de una red probabilística para el eje Z (s.p.). ....	98
Figura 6.20: Gráfico de clasificación de una red probabilística para el eje Z (s.p.). ....	98
Figura 6.21: Gráfico de clasificación de una red de reconocimiento de patrones según el eje X (c.p.). ....	103
Figura 6.22: Gráfico de la eficiencia de clasificación de una red de reconocimiento de patrones según el eje X (c.p.). ....	104
Figura 6.23: Gráfico de clasificación para el eje Y de una red de reconocimiento de patrones (c.p.). ....	106
Figura 6.24: Eficiencia de la clasificación según el eje Y de una red de reconocimiento de patrones (c.p.). ....	106
Figura 6.25: Gráfico de clasificación de una red de reconocimiento de patrones para el eje Z (c.p.). ....	108
Figura 6.26: Evolución de la clasificación del eje Z para una red de reconocimiento de patrones (c.p.). ....	108
Figura 6.27: Gráfico de clasificación para el eje X de una red de reconocimiento de patrones (s.p.). ....	111
Figura 6.28: Gráfico de clasificación de una red de reconocimiento de patrones para el eje X (s.p.). ....	112
Figura 6.29: Gráfico de clasificación de una red de reconocimiento de patrones según el eje Y (s.p.). ....	114
Figura 6.30: Gráfico de la eficiencia de clasificación según el eje Y para una red de reconocimiento de patrones (s.p.). ....	114
Figura 6.31: Gráfico de clasificación de una red de reconocimiento de patrones para el eje Z (s.p.). ....	116
Figura 6.32: Evolución de la clasificación del eje Z para una red de reconocimiento de patrones (s.p.). ....	116
Figura 7.1: Eficiencia según el nivel de descomposición y tipo de red. ....	123
Figura 9.1: Plano superior de la máquina Rotokit. ....	131
Figura 9.2: Plano frontal de la máquina de ensayos Rotokit. ....	132
Figura 9.3: Plano lateral del Rotokit. ....	133



## ÍNDICE DE TABLAS

Tabla 3.1: Características del motor MARATHON 56T34F5301 J.....	41
Tabla 3.2: Características del variador de frecuencia Delta VFD 007S21B. ....	42
Tabla 3.3: Características del acelerómetro MMF KS943B.10. ....	50
Tabla 3.4: Características de los acondicionadores de señal MMF M32. ....	54
Tabla 3.5: Características básicas de la tarjeta de adquisición de datos Keithley KUSB-3100. ...	55
Tabla 5.1: Valores de validación y test de la red de reconocimiento de patrones. ....	74
Tabla 6.1: Paquetes óptimos correspondientes al eje X.....	82
Tabla 6.2: Relación de paquetes óptimos para el eje Y. ....	83
Tabla 6.3: Paquetes óptimos referentes al eje Z. ....	84
Tabla 6.4: Resultados de clasificación de una red probabilística para el eje X (c.p.). ....	86
Tabla 6.5: Resultados de clasificación según el eje Y para una red probabilística (c.p.). ....	88
Tabla 6.6: Resultados de clasificación de una red probabilística según el eje Z (c.p.). ....	90
Tabla 6.7: Resultados de clasificación de una red probabilística para el eje X (s.p.). ....	93
Tabla 6.8: Resultados de clasificación según el eje Y para una red probabilística (s.p.). ....	95
Tabla 6.9: Resultados de clasificación de una red probabilística según el eje Z (s.p.). ....	97
Tabla 6.10: Resultados de clasificación de una red de base radial según el eje X (c.p.). ....	100
Tabla 6.11: Resultados de clasificación de una red reconocimiento de patrones según el eje X (c.p.). ....	102
Tabla 6.12: Resultados de clasificación según el eje Y para una red de reconocimiento de patrones (c.p.). ....	105
Tabla 6.13: Resultados de clasificación de una red reconocimiento de patrones para el eje Z (c.p.). ....	107
Tabla 6.14: Resultados de clasificación de una red de reconocimiento de patrones según el eje X (s.p.). ....	110
Tabla 6.15: Resultados de clasificación según el eje Y para una red de reconocimiento de patrones (s.p.). ....	113
Tabla 6.16: Resultados de clasificación de una red de reconocimiento de patrones para el eje Z (s.p.). ....	115
Tabla 6.17: Desglose presupuestario (equipos).....	117
Tabla 6.18: desglose presupuestario (personal).....	118
Tabla 6.19: Resumen de costes. ....	118
Tabla 7.1: Resultados de la eficiencia de clasificación por eje.....	120
Tabla 7.2: Resultados de la eficiencia de clasificación según el nivel de descomposición.....	121
Tabla 7.3: Resultados según la zona estudiada. ....	121
Tabla 7.4: Eficiencia de clasificación por tipo de red. ....	122
Tabla 7.5: Resultados según el nivel de descomposición y red empleada.....	122
Tabla 9.1: Resultados de clasificación de una red de base radial para el eje Y (c.p.).....	134
Tabla 9.2: Resultados de clasificación según el eje Z para una red de base radial (c.p.). ....	135
Tabla 9.3: Resultados de clasificación según el eje X para una red de base radial (s.p.). ....	136
Tabla 9.4: Resultados de clasificación según el eje Y para una red de base radial (s.p.). ....	137
Tabla 9.5: Resultados de clasificación de una red de base radial según el eje Z (s.p.).....	138



# **Capítulo 1:**

## Introducción



## 1. INTRODUCCIÓN

### 1.1 ANTECEDENTES

Un eje es un componente fundamental en máquinas para la transmisión de potencia, así como para soportar otros elementos de la máquina. A este elemento, además, se le exige un funcionamiento fiable a unas velocidades y con cargas cada vez mayores. Por todo ello, es conveniente realizar un seguimiento del estado del eje como medida de precaución ante un posible fallo del eje que podría provocar unos serios daños en el resto de la máquina.

De esta forma han surgido diferentes tipos de mantenimiento en función del momento en que se realizan, el objetivo para el que se ponen en marcha y según los recursos utilizados. Los cuatro modelos de mantenimiento existentes son los siguientes:

#### 1. Mantenimiento correctivo

Este mantenimiento también denominado “mantenimiento reactivo”, tiene lugar después de ocurrir una falla o avería, es decir, sólo se actúa cuando se presenta un error en el sistema. En este caso si no se produce ninguna avería, no se realizará ninguna operación de mantenimiento, por lo que se tendrá que esperar hasta que se presente el fallo para tomar medidas. Este mantenimiento trae consigo las siguientes consecuencias:

- Paradas no previstas en el proceso productivo, disminuyendo las horas operativas.
- Afecta a las cadenas productivas, es decir, que los ciclos productivos posteriores se verán afectados, pudiendo estar parados a la espera de la corrección de la etapa anterior.
- Presenta costes por reparación y repuestos no presupuestados, por lo que se puede dar el caso de que, por falta de recursos económicos, no se puedan comprar los repuestos en el momento deseado.
- La imposibilidad de planificar el tiempo que estará el sistema fuera de servicio.

#### 2. Mantenimiento preventivo

Este mantenimiento también se denomina “mantenimiento planificado”, puesto que tiene lugar antes de que ocurra una falla o avería y se efectúa bajo condiciones controladas sin la existencia de errores en el sistema. Se realiza a razón de la experiencia y pericia del personal, los cuales son los encargados de determinar el momento necesario para llevar a cabo dicho proceso. El fabricante también puede estipular el momento adecuado a través de los manuales técnicos. Este método requiere, como es evidente, parar y arrancar la máquina, lo cual puede tener un coste económico importante al dejar de producir dicha máquina, además de realizar un ciclo de parada-arranque que es uno de los momentos más críticos para la máquina y en especial, para el caso en el que hubiera algún tipo de fisura cuya propagación



se vea favorecida por las cargas generadas durante esta operación. Las características de este tipo de mantenimiento son las siguientes:

- Se realiza en un momento en el que no se está produciendo, por lo que se aprovechan las horas ociosas de la planta.
- Se lleva a cabo un programa previamente elaborado, donde se detallan el procedimiento a seguir y las actividades a realizar, a fin de tener las herramientas y repuestos necesarios “a mano”.
- Cuenta con una fecha programada, además de un tiempo de inicio y de terminación preestablecido y aprobado por la directiva de la empresa.
- Está destinado a un área en particular y a ciertos equipos específicamente, aunque también se puede llevar a cabo un mantenimiento generalizado de todos los componentes de la planta.
- Permite a la empresa contar con un historial de todos los equipos, brindando además la posibilidad de actualizar la información técnica de los mismos.
- Permite contar con un presupuesto aprobado por la directiva.

### 3. Mantenimiento predictivo

Consiste en determinar en todo instante la condición técnica (mecánica y eléctrica) real de la máquina examinada, mientras ésta se encuentra en pleno funcionamiento, para lo cual se hace uso de un programa sistemático de mediciones de los parámetros más importantes del equipo. El sustento tecnológico de este mantenimiento consiste en la aplicación de algoritmos matemáticos agregados a las operaciones de diagnóstico, que juntos pueden brindar información referente a las condiciones del equipo. Tiene como objetivo disminuir las paradas por mantenimiento preventivo y, de esta manera, minimizar los costes por mantenimiento y por parada de producción. La implementación de este tipo de métodos requiere de una inversión en equipos, instrumentos y contratación de personal cualificado. Entre las técnicas utilizadas para el desarrollo del mantenimiento predictivo se encuentran:

- Análisis de Fourier (para análisis de vibraciones).
- Endoscopia (para poder ver lugares ocultos).
- Ensayos no destructivos (a través de líquidos penetrantes, ultrasonidos, radiografías, partículas magnéticas, etc.).
- Termovisión (detección de condiciones a través del calor generado).



- Medida de parámetros de operación (viscosidad, voltaje, corriente, potencia, presión, temperatura, etc.).

#### 4. Mantenimiento proactivo

Este mantenimiento tiene como fundamento los principios de solidaridad, colaboración, iniciativa propia, sensibilización, trabajo en equipo, de tal modo que todos los involucrados, directa o indirectamente, en la gestión del mantenimiento deben conocer la problemática del mantenimiento, es decir, que tanto técnicos, profesionales, ejecutivos y directivos deben ser conscientes de las actividades que se llevan a cabo para desarrollar las labores de mantenimiento. Cada individuo, desde su cargo o función dentro de la organización, actuará de acuerdo a este cargo, asumiendo un rol en las operaciones de mantenimiento, bajo la premisa de que se debe atender las prioridades del mantenimiento de forma oportuna y eficiente. El mantenimiento proactivo implica contar con una planificación de operaciones, la cual debe estar incluida en el plan estratégico de la organización. Este mantenimiento a su vez debe brindar indicadores (informes) hacia la gerencia, respecto del progreso de las actividades, los logros, aciertos, y también errores [1].

Como se ha visto en anteriores líneas (mantenimiento predictivo) existe la opción de realizar un seguimiento continuo del estado del eje mediante la monitorización de algún parámetro de operación de la máquina. Generalmente, se suelen monitorizar las vibraciones sufridas por el elemento en cuestión.

El principal problema de este método no es el de medir dichas vibraciones, ya que para esto basta con un simple acelerómetro, sino el hecho de distinguir el origen de las mismas, puesto que las vibraciones pueden estar motivadas por diferentes causas como pueden ser desequilibrios, desalineamiento de ejes, holguras de tornillos y tuercas, rozamiento, defectos en rodamientos, fisuras en el eje, etc. [2].

Para identificar estos problemas se ha empleado generalmente el análisis de Fourier para analizar las señales obtenidas, pero es difícil la detección de fisuras y su evaluación. Este problema para detectar fisuras en ejes ha atraído el interés de muchos expertos debido a su importancia. Los investigadores han presentado sus logros en forma de órbitas, análisis espectral de frecuencia y wavelets. Algunos presentan armónicos 1X y 2X como el principal factor para la detección de fisuras, otros se basan en sub-armónicos, mientras que unos pocos establecen la presencia de señales transitorias como factor de identificación de fisuras. Por tanto, muchos expertos en la materia necesitan todavía un mayor conocimiento sobre la presencia de fisuras, su propagación e identificación. Debido a la frecuencia prevista y a la variación de amplitud, la atención está dirigida al uso del análisis de la transformada wavelet para el análisis de las vibraciones del eje, ya que el uso del análisis de Fourier no permite diferenciar con precisión las señales generadas entre un eje sin fisura y otro con fisura [2].

Algunas características únicas del uso de wavelets son que permiten manejar tanto señales estacionarias como no estacionarias y puede transformar cualquier señal directamente en los dominios tiempo / espacio y frecuencia / escala, proporcionando información detallada



sobre la evolución de la señal. Este método se puede aplicar en la detección de puntos de discontinuidad y de falla, supresión de la señal, compresión de la señal y procesado de imagen.

Una vez analizadas las señales obtenidas, es necesario clasificarlas para diferenciarlas entre las diferentes fisuras. Con el desarrollo de las redes neuronales, se puede implementar un sistema que clasifique cualquier señal dentro de un conjunto de grupos.

Las redes neuronales empleadas para la detección de defectos se basan en el reconocimiento de patrones, por el cual, a partir de una muestra de señales, son capaces de diferenciar una serie de patrones que permitan distinguir dichas señales y clasificarlas en diferentes grupos. Este proceso se denomina *aprendizaje* y permite que las redes neuronales artificiales aprendan basándose en hechos de forma parecida a como lo hace el cerebro humano de manera totalmente natural. Esta etapa de aprendizaje es la base para que la red neuronal sea capaz de clasificar posteriormente cualquier nueva señal según se corresponda con el patrón de una clase u otra de las generadas en el proceso de aprendizaje. De esta forma, se consigue realizar la misma tarea que haría cualquier experto en la materia que analizase las señales obtenidas, con la única diferencia de que aquí es un sistema el que realiza dicha función, evitando la intervención humana en el diagnóstico.

## **1.2 OBJETIVOS DEL PROYECTO**

El objetivo principal de este proyecto es estudiar diferentes ejes iguales con y sin fisura, de forma que, a partir de las vibraciones medidas con los ejes en funcionamiento, se pueda identificar el tipo de fisura mediante el empleo de diferentes tipos de redes neuronales. Para ello se empleará un banco de ensayos denominado Rotokit perteneciente al departamento de Ingeniería Mecánica de la Universidad Carlos III de Madrid.

Otros objetivos previos necesarios para la consecución del objetivo expuesto en el párrafo anterior son los siguientes:

- Puesta a punto del banco de ensayos donde se montarán los diferentes ejes y determinación de los ensayos a realizar.
- Integración del sistema de medida dentro del banco de ensayos. Este sistema de medida está compuesto por un acelerómetro, unos filtros / amplificadores, una tarjeta de adquisición de datos y el software adecuado.
- Selección de los parámetros adecuados del sistema de medida que permitan obtener los mejores resultados en cuanto a la adquisición de las señales que se emplearán posteriormente.
- Aplicación del análisis mediante wavelets de las señales obtenidas de los ensayos realizados a los ejes en estudio.



- Selección de las redes neuronales artificiales ofrecidas por el programa MATLAB® más adecuadas para la clasificación de los tipos de fisuras. Esta elección se fundará en redes neuronales basadas en el reconocimiento de patrones.
- Comparación entre los resultados logrados para cada tipo de red neuronal variando los parámetros de las mismas.
- Comparación entre los resultados obtenidos de las redes neuronales empleadas.
- Análisis de los resultados y obtención de conclusiones.

## **1.3 ESTRUCTURA DEL DOCUMENTO**

El presente proyecto se compone de 9 capítulos. En el capítulo 2 se describirá el esquema de proceso seguido, así como también se desarrollará una descripción teórica del análisis wavelet empleado para el procesamiento de las señales vibratorias. Por último, en este segundo capítulo se llevará a cabo una introducción a las redes neuronales artificiales y se procederá a detallar en mayor medida los tres tipos de redes neuronales empleadas para la clasificación de los datos generados en el análisis wavelet.

Por otro lado, en el capítulo 3, se mostrará el sistema experimental utilizado para la adquisición de las señales de vibración generadas durante la operación del eje. Este sistema consta de la máquina de ensayos Rotokit empleada para simular las condiciones de funcionamiento de los ejes, un acelerómetro situado en la máquina de ensayos, unos filtros / amplificadores que acondicionan la señal y una tarjeta de adquisición de datos que permite manejar las señales mediante un ordenador.

A continuación en el capítulo 4, se realizará una breve exposición acerca del software empleado en el desarrollo de este proyecto. Primero se hablará sobre el programa TestPoint™, utilizado para la adquisición de datos y en segundo lugar se procederá a hacer lo mismo con el programa MATLAB®, usado para el análisis wavelet y cuyas redes neuronales, correspondientes a la Neural Network Toolbox™, se han empleado para la clasificación de los diferentes ejes.

En el capítulo 5 se explicará el desarrollo del proyecto, especificando los ensayos realizados y los parámetros elegidos para ellos, además de exponer los programas empleados en el tratamiento de las señales.

Los resultados de los ensayos se presentarán en el capítulo 6. En este capítulo se definirán los ensayos realizados y se analizarán los resultados de los mismos. También se incluirá el presupuesto detallado de los costes de este proyecto.

En el capítulo 7 se mostrarán las conclusiones obtenidas de este proyecto así como posibles mejoras aplicables a futuros trabajos relacionados con el presente proyecto.

Los capítulos 8 y 9 se corresponden con la bibliografía utilizada y con los anexos del proyecto respectivamente.



# **Capítulo 2:**

## Contexto teórico



**2. CONTEXTO TEÓRICO**

En este capítulo se procederá a dar una breve introducción teórica sobre el esquema de proceso empleado en el desarrollo de este proyecto, así como sobre un método de análisis de señales cada vez más empleado en la actualidad denominado transformada wavelet. Además, se presentarán las ventajas de este tipo de análisis frente al de Fourier y las transformadas wavelet continua y discreta.

Por otra parte, se desarrollará una breve descripción acerca de las redes neuronales artificiales como sistema de clasificación. Para ello, se procederá a dar diferentes definiciones de redes neuronales, continuando por la evolución que se ha logrado en este campo. Posteriormente, se entrará en mayor detalle sobre las bases teóricas de las redes neuronales, terminando con los tipos de redes empleadas para el desarrollo del proyecto.

**2.1 INTRODUCCIÓN**

Tal y como se ha comentado en el capítulo anterior, la industria tiende cada vez más a la monitorización de los sistemas en tiempo real, empleando procesos de adquisición, procesamiento y clasificación de señales, tal y como se puede ver en la figura 2.1.

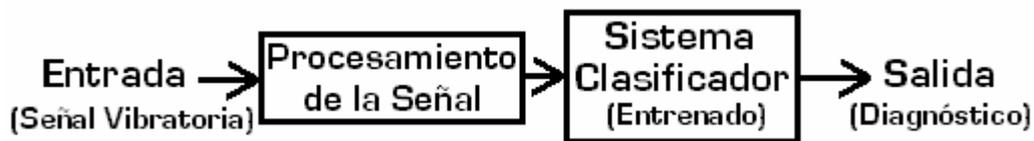


Figura 2.1: Esquema de proceso de monitorización y diagnóstico [3].

El presente proyecto se basa en el esquema de proceso mostrado en la figura 2.1, en el que la diagnosis del proceso se realiza de forma directa, sin pasar por las etapas de detección e identificación del defecto, que son fases típicas en la monitorización tradicional de procesos industriales, mostrado en la figura 2.2.

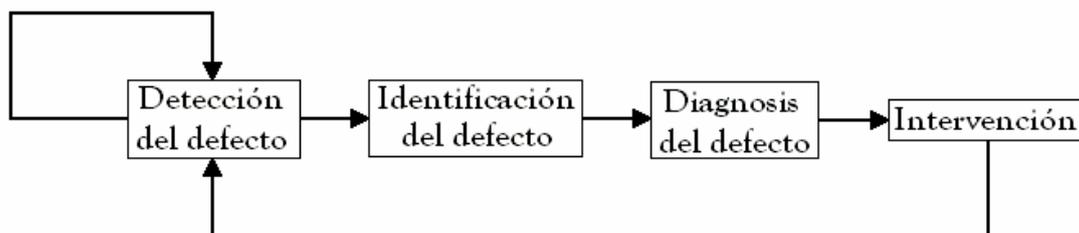


Figura 2.2: Esquema tradicional de la monitorización de procesos industriales [3].



En el caso que nos incumbe, las vibraciones medidas son la entrada al sistema de monitorización y después se procesan con el fin de buscar información relevante del estado de los componentes en estudio. Posteriormente, un sistema clasificador se encarga de proporcionar el diagnóstico de la condición del sistema, lo que disminuye la influencia humana en los resultados del proceso de monitorización.

El objetivo de este método es evaluar el estado dinámico del sistema de manera permanente, ofreciendo un diagnóstico continuado de su condición, lo cual proporciona la ventaja de detectar un cambio en las condiciones de los componentes, es decir, la evolución de un estado “sin defecto” a otro “con defecto”, con suficiente antelación.

### **2.2 DESCOMPOSICIÓN WAVELET**

#### **2.2.1 INTRODUCCIÓN**

En la ingeniería habitualmente se representan las señales mediante funciones de tiempo  $f(t)$  o, alternativamente, en el dominio de la frecuencia a través de su Transformada de Fourier  $F(w)$ . Ambas representaciones contienen exactamente la misma información sobre la señal, respondiendo a enfoques distintos y complementarios. Las wavelets son una extensión del análisis de Fourier y, al igual que ocurre con el análisis de Fourier, éstas no son lo realmente importante, sino que lo verdaderamente importante es el objeto para lo que son creadas. Su objetivo es convertir en números la información contenida en una señal, números conocidos como coeficientes, que se pueden manipular, almacenar, transmitir, analizar o utilizar para reconstruir la señal original. Una función wavelet es una forma de onda de duración limitada que tiene un valor promedio cero. Dentro de las ventajas de las wavelet que se pueden mencionar se encuentran la de ofrecer información instantánea en tiempo y frecuencia para cada punto de la señal, satisfacer condiciones de multirresolución, ser ajustable y adaptable, entre otras [4].

#### **2.2.2 HISTORIA DE LAS WAVELET**

Puede decirse que la primera referencia al concepto de wavelet está asociada a Jean Baptiste Joseph Fourier puesto que sus trabajos en 1807 sobre la transformada de Fourier a través de senos y cosenos permitieron representar casi cualquier señal; esto significa que Fourier abrió la puerta hacia un nuevo mundo. En 1909 fue la primera vez que se mencionó la palabra wavelet, en la tesis de A. Haar [5]. Una propiedad de la wavelet de Haar es su soporte compacto. La principal desventaja de esta wavelet es que no puede ser diferenciable de manera continua por lo que puede limitar sus aplicaciones. En 1930 Paul Levy notó en una de sus aplicaciones sobre el movimiento Browniano que la wavelet de Haar era más apropiada para la descomposición de la señal que el tratamiento a través de senos y cosenos de Fourier. En algunos trabajos realizados entre 1960 y 1980 Guido Weiss y Ronald R. Coifman estudiaron lo que denominaron “átomos”, elementos a partir de los cuales era posible la reconstrucción de una señal. En la década de los 80, Grossman y Morlet definieron las wavelet en el contexto



de la física cuántica [6]. En esta misma década Stephane Mallat dio un salto importante a través de su trabajo sobre el procesamiento digital de señales [7]. Por otro lado, Meyer construyó la primer wavelet no trivial, la cuál era continuamente diferenciable. Ingrid Daubechies se apoyó en el trabajo de Mallat para construir un grupo de funciones básicas ortogonales de wavelet, las que resultan ser, la más depurada versión de las wavelet y pilar de las wavelets actuales y sus aplicaciones [8].

### **2.2.3 TRANSFORMADA WAVELET CONTINUA**

La transformada wavelet continua es un operador lineal que asocia con cada señal de energía finita y con una función particular  $\Psi$  y denominada wavelet madre, elegida convenientemente en función de la señal, un número real o complejo, una vez seleccionado el instante y la escala de observación [9]. El empleo de las wavelets permite realizar análisis localizados en el tiempo de una gran señal, brindando la posibilidad de encontrar discontinuidades o picos de corta duración que de otra manera sería complicado detectar y tratar, mostrando aspectos de los datos que con otras técnicas del análisis de señales no pueden ser apreciadas y se dejan pasar por alto [10].

Sea  $f(t)$  una señal del espacio  $L^2(\mathbb{R})$  y  $\Psi$  una wavelet madre, para la que más tarde se darán especificaciones. Las denominadas wavelets analizadoras se construyen partiendo de  $\Psi$ , realizando sobre ella operaciones de traslación en el tiempo y dilatación, de forma que la posicionan y la dilatan hasta conseguir el efecto de análisis deseado. La wavelet madre  $\Psi$  se define como:

$$\psi(t) = \frac{1}{\sqrt{|a|}} \psi\left(\frac{t-b}{a}\right) \quad (1)$$

donde  $a \neq 0$  y  $b$  son los parámetros de escala y de traslación. Se preserva la energía de las funciones mediante un factor de normalización. La función  $\Psi(t)$  debe verificar ciertas condiciones de admisibilidad, mientras que el resto de las funciones generadas denominadas *wavelets* se denotan como [11]:

$$\psi_{a,b}(t) = \frac{1}{\sqrt{|a|}} \psi\left(\frac{t-b}{a}\right) \quad (2)$$

Las condiciones de admisibilidad básicamente requieren que la función  $\Psi(t)$  esté bien localizada en tiempo, tenga valor medio nulo y que la transformada  $\Psi(\omega)$  sea un filtro continuo pasa-banda, con rápido decaimiento hacia el infinito y hacia  $\omega = 0$ . Así, dada una señal  $s(t)$ , de energía finita, la *Transformada Wavelet Continua* de  $s(t)$  se define para cada pareja de parámetros reales  $(a, b)$ ,  $a \neq 0$  como:

$$W_{\psi} s(a, b) = \int_{-\infty}^{\infty} s(t) \psi_{a,b}(t) dt \quad (3)$$

Si la wavelet es real, la definición se restringe para valores positivos de  $a$ . La transformación así definida preserva la energía de la señal, y posee una fórmula integral de inversión. Si la wavelet madre es real, la reconstrucción se realiza como:



$$s(t) = C_\psi \int_0^\infty \int_{-\infty}^\infty W_\psi s(a, b) \psi_{a,b}(t) \frac{db da}{a^2}$$

donde  $C_\psi$  es una constante positiva.

La fórmula expresa la síntesis de la señal como la superposición integral de las funciones elementales  $\psi_{a,b}(t)$ . El mapeo sobre dominio tiempo-frecuencia, parametrizado por  $(a, b)$ , representa una novedosa alternativa a la Transformada de Fourier por ventanas.

Cualquier wavelet real admisible  $\psi(t)$  está bien localizada en un intervalo centrado en un  $t_0$ , de longitud  $\Delta t$  y cuya transformada  $\Psi(\omega)$  está localizada en una banda  $0 < \omega_1 \leq |\omega| \leq \omega_2$ , de ancho  $\Delta\omega$ . Entonces, las wavelets  $\psi_{a,b}(t)$  están localizadas en el intervalo centrado en  $at_0 + b$ , de longitud  $a\Delta t$  y en la banda  $0 < \omega_1/a \leq |\omega| \leq \omega_2/a$ , de ancho  $\Delta\omega$ . Al mismo tiempo, se observa que la precisión en tiempo es inversamente proporcional a la precisión en frecuencia, manteniéndose constante la relación  $\Delta t \cdot \Delta\omega$ , es decir, este tipo de análisis proporciona alta resolución en el tiempo y baja en frecuencia con señales de alta frecuencia mientras que ofrece baja resolución temporal y alta resolución frecuencial con señales de baja frecuencia. Permite superar algunas de las limitaciones del análisis de Fourier sin embargo, se debe remarcar que la limitación en la resolución tiempo-frecuencia expresada en el Principio de Incertidumbre es insalvable cualquiera que sea la herramienta matemática que se emplee [12].

Más aún, para cada valor de  $a$ , la familia de wavelets parametrizada por  $b$ , se comporta como una ventana deslizante, de ancho de banda constante, pero el número de oscilaciones de estas ondas elementales es siempre el mismo, en el marco efectivo de la ventana.

Por otra parte, si la transformada  $\Psi(\omega)$  decae rápidamente a cero en torno de  $\omega=0$ , se verifica la propiedad de oscilación:

$$\int_{-\infty}^\infty t^k \psi(t) dt = 0$$

para  $k=0, \dots, K$ . Esta importante propiedad es transcendental en las aplicaciones de análisis de señales, para la detección de fenómenos puntuales, como discontinuidades o bruscos cambios en las derivadas.

**2.2.4 LAS WAVELETS Y LAS FUNCIONES SENOIDALES**

El análisis de Fourier descompone, mediante sus coeficientes, una señal en senos y cosenos de diferentes frecuencias y amplitudes; de forma similar el análisis wavelet descompone una señal en una versión desplazada y escalada de otra señal denominada wavelet madre ( $\Psi$ ). En la figura 2.3 se muestra un ejemplo de descomposición de una señal para cada uno de estos dos tipos de análisis comentados. Escogiendo adecuadamente la wavelet madre, se puede descomponer la señal a tratar de manera más apropiada, sin limitarse exclusivamente a las funciones seno o coseno que no siempre se ajustan rápidamente a la forma irregular de la señal tratada. Si se comparan las wavelets con las ondas

seno se puede notar que la wavelet tiene duración definida; además, las wavelets tienden a ser irregulares y asimétricas, lo que permite mayor adaptabilidad y mejor convergencia a la señal a tratar, de ahí la importancia de seleccionar adecuadamente la wavelet madre y no dejar al azar la selección de la misma.

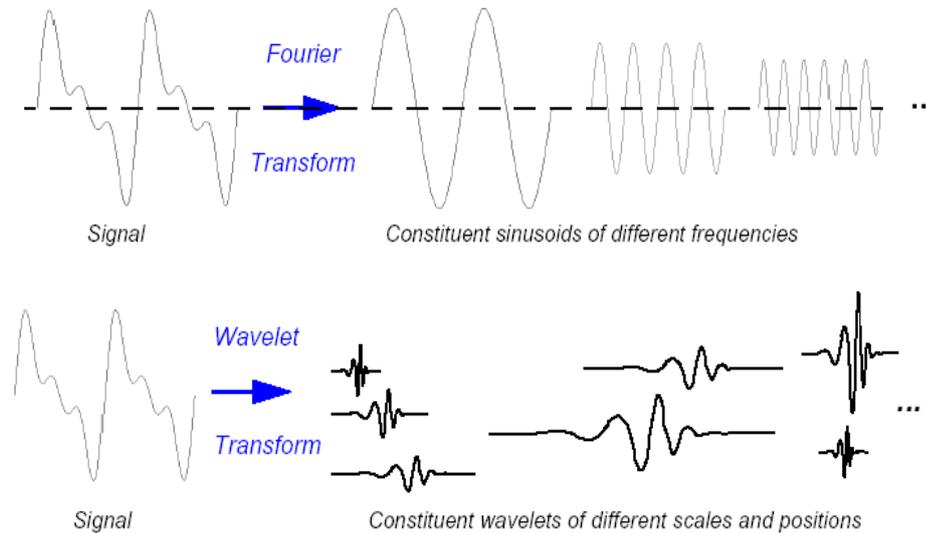


Figura 2.3: Descomposición de una señal en ondas [10].

Como ya se ha comentado en este capítulo, el empleo de las wavelets permite realizar análisis localizados en el tiempo de una gran señal, brindando la posibilidad de encontrar discontinuidades o picos de corta duración que de otra manera sería complicado detectar y tratar, mientras que el análisis FFT (del inglés Fast Fourier Transform o transformada rápida de Fourier, que es una aplicación práctica a la transformada de Fourier) por sí sólo no detecta estos eventos, al perder casi toda la información temporal, puesto que todo el espectro de Fourier se verá afectado, y debe recurrir a la transformada corta de Fourier (STFT), que mediante la selección de una ventana de ancho adecuado permite el estudio de manera aceptable. En la figura 2.4 se muestran algunas de las wavelets madre más comúnmente empleadas.

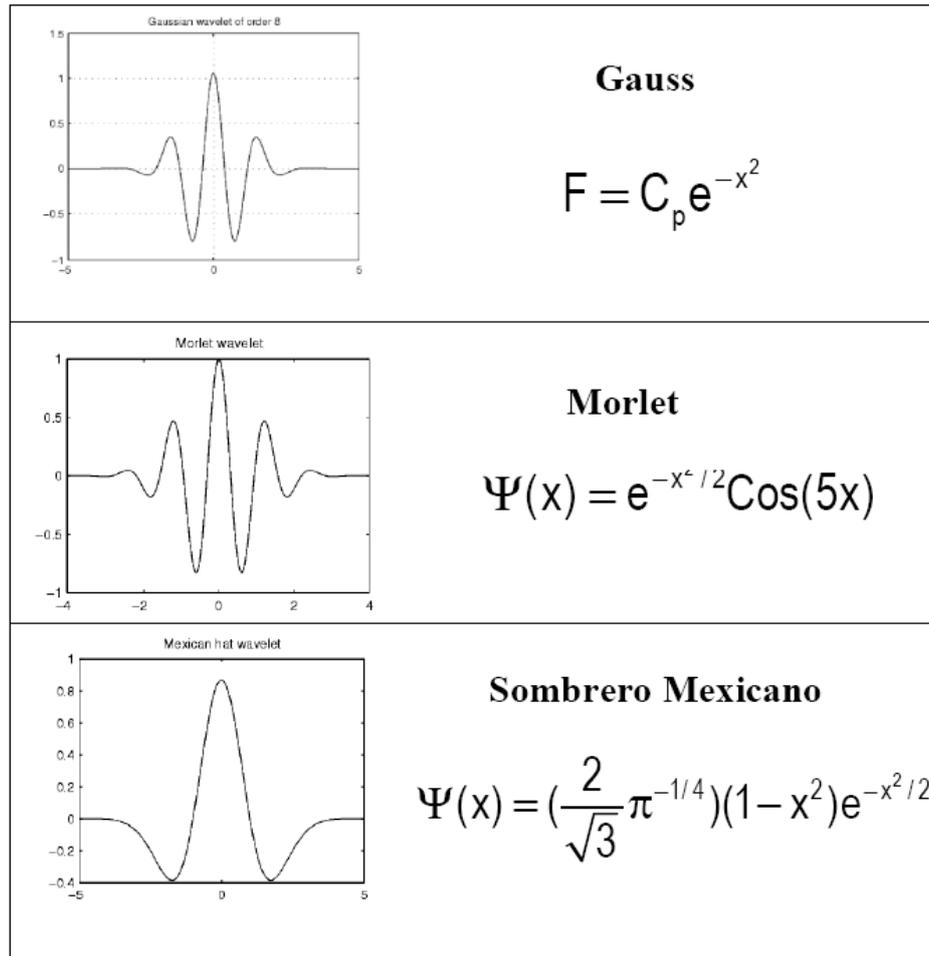


Figura 2.4: Wavelets madre típicas [4].

Los coeficientes empleados tanto en el análisis de Fourier como en el análisis wavelet, indican en qué forma se debe modificar la señal que apoya el análisis (seno, coseno, wavelet) para reconstruir la señal original. Prácticamente se puede reconstruir una señal agregando wavelets de diferentes tamaños (ecuaciones 3 y 4), en diferentes posiciones, de forma análoga a como el análisis de Fourier reconstruye la señal agregando senos o cosenos de diferentes frecuencias y amplitudes (ecuaciones 5 y 6). En las siguientes líneas se muestran las ecuaciones correspondientes a la transformada wavelet y su inversa (ecuaciones 4 y 5) y también las referentes a la transformada de Fourier y su respectiva inversa (ecuaciones 6 y 7).

*Transformada wavelet:* 
$$W(a, b) = \int_{-\infty}^{\infty} f(t) \frac{1}{\sqrt{|a|}} \psi\left(\frac{t-b}{a}\right) dt \quad (4)$$

*Transformada inversa wavelet:* 
$$f(t) = \frac{1}{k^2} \iint_{-\infty}^{\infty} W(a, b) \frac{\psi\left(\frac{t-b}{a}\right)}{a^2} da \cdot db \quad (5)$$

*Transformada de Fourier:* 
$$F(\omega) = \int_{-\infty}^{\infty} f(t) \cdot e^{-j\omega t} dt \quad (6)$$

*Transformada inversa de Fourier:* 
$$f(t) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} F(\omega) \cdot e^{j\omega t} \cdot d\omega \quad (7)$$

El proceso de alargar y comprimir la wavelet mediante su escalado a través del parámetro  $a$  de la ecuación (1) para cambiar su frecuencia modifica todo. Las wavelets se adaptan automáticamente para diferentes componentes de una señal. El hecho de alargar la wavelet permite ver la señal de una manera general ampliada y el comprimirla deja ver detalles de la misma, por lo que la wavelet se considera un “microscopio matemático”. La transformada wavelet es una técnica relativamente nueva en el campo del mantenimiento industrial que resulta ser una poderosa herramienta en el análisis sobre el comportamiento local de una señal. Este hecho implica que, aunque en los últimos años se ha realizado un gran esfuerzo por darle todo el rigor matemático que tiene la transformada de Fourier y unificar métodos y notaciones, el ritmo de aparición de publicaciones sobre el tema hace que no sea tarea fácil. Al igual que la STFT, esta transformada utiliza una función ventana que enmarca la señal dentro de un intervalo y se centra en ese segmento de la señal. Sin embargo, en la WT el uso de intervalos de larga duración se realiza con ventanas de tamaño ajustable (a diferencia de la STFT que el tamaño de la ventana es fija). Estas funciones ventana se muestran en la figura 2.5, donde se exponen las representaciones espectrales de estos dos tipos de análisis y en la que se observa que la ventana empleada por el análisis de Fourier es de tamaño fijo, ya que todas las divisiones en frecuencia son iguales, al igual que su amplitud, al contrario de los que sucede con el análisis wavelet, donde la señal se divide en intervalos iguales pero cuyo tamaño varía en función del escalado empleado, pudiendo estudiar el mismo período de tiempo en diferentes intervalos según el parámetro de escala seleccionado.

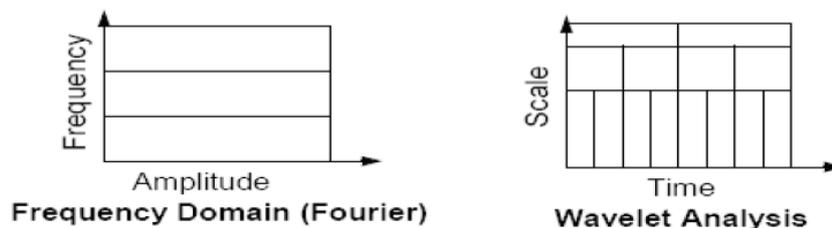


Figura 2.5: Representaciones espectrales para el análisis de Fourier y el análisis wavelet [10].

Otras diferencias importantes, además de las ya comentadas, entre el análisis wavelet y el de Fourier son las siguientes [10]:

- Cuando un sistema es lineal y los modos de vibración son modos propios del sistema, el análisis de Fourier proporciona mucha información sobre los mismos. Pero si no es así, la descomposición en modos propios no da información interesante, ya que mezcla la información de los diferentes modos de oscilación.
- Al estudiar sistemas no lineales que no tienen modos propios, ninguna descomposición global en el espíritu del análisis de Fourier tendrá éxito. Uno se debe limitar a una expansión local en modos, que es lo que hace el análisis de wavelets (como un desarrollo tipo Taylor).
- La Transformada Wavelet Discreta presenta además claras ventajas frente a Fourier:



- Es más rápida desde el punto de vista computacional: del orden de  $O(N)$  [DWT], frente a  $O(N \log N)$  [FFT] para una muestra de  $N$  datos.
  - En muchos casos proporciona un mejor ajuste a los datos con menos coeficientes. (Permitiendo una mejor compresión de los datos).
  - Las técnicas de filtrado de ruido basadas en wavelets dan mejores resultados.
- No permite realizar algunos cálculos como los relacionados con la convolución o la modulación de una señal.

### **2.2.5 TRANSFORMADA WAVELET DISCRETA**

La transformada wavelet continua presenta tres propiedades que hacen su uso difícil y directo. La primera de ellas es la redundancia de la transformación continua de wavelets. En la ecuación (3) la transformación de wavelets es calculada por cambios continuos y funciones continuas de escalamiento sobre señales y calcular entonces la correlación entre ellas. El segundo problema que aparece es que una vez eliminada la redundancia, todavía existe un número infinito de wavelets en la transformación y lo mejor es tener un número manejable de wavelets. Por último, el tercer problema es que, para la mayoría de las funciones, las transformaciones no cuentan con soluciones analíticas y pueden ser calculadas sólo numéricamente, necesitándose algoritmos rápidos para explotar el poder de las transformaciones wavelets. Con el fin de evitar estos problemas, se emplea la transformada wavelet discreta [13].

Por la complejidad en el tratamiento numérico de la transformada wavelet discreta (DWT), debido a la variabilidad en forma continua de los parámetros de escala como de traslación, es indispensable contar con una herramienta que permita la discretización de ésta. Es así que se pasará de un mapeo continuo a un espectro o conjunto finito de valores, a través del cambio de la integral por una aproximación con sumatorias. La discretización permite representar una señal en términos de funciones elementales acompañadas de coeficientes [14].

En los sistemas Wavelet, las Wavelet madre  $\psi(t)$  traen consigo unas funciones de escala  $\phi(t)$ , donde las primeras son las encargadas de representar los detalles finos de la función mientras que las funciones de escala realizan una aproximación. Es posible entonces representar una señal como una sumatoria de funciones wavelet y funciones de escala:

$$f(t) = \sum_k \sum_j c_{j,k} \phi(t) + \sum_k \sum_j d_{j,k} \psi(t)$$

Una forma de discretizar los parámetros de escala y frecuencia es mediante un muestreo exponencial, para garantizar una mejor aproximación, con el cual se obtiene la familia de funciones discretizadas, que constituyen bases ortonormales de Wavelets en  $L^2(\mathbb{R})$ .



$$\psi_{j,k}(t) = \frac{1}{\sqrt{a^{-j}}} \psi\left(\frac{t - kna^{-j}}{a^{-j}}\right)$$

Para obtener una mejor aproximación de la señal en niveles de resolución muy finos, es necesario que las Wavelet sean dilatadas por un factor de  $2^j$ , permitiendo tener una resolución de  $2^j$ , estas funciones se denominan Wavelets Diádicas [14].

$$\psi_{j,k}(t) = 2^{\frac{j}{2}} \psi(2^j t - kn) \quad j, k \in \mathbb{Z}$$

Por lo que la transformada discreta wavelet tiene la siguiente forma:

$$DWT f(j, k) = \int_{-\infty}^{\infty} f(t) 2^{\frac{j}{2}} \psi(2^j t - kn) dt$$

Teniendo en cuenta este procedimiento es posible generar una familia de funciones de escala definidas:

$$\phi_{j,k}(t) = 2^{\frac{j}{2}} \phi(2^j t - kn) \quad j, k \in \mathbb{Z}$$

La representación general de la señal  $f(t)$  será de la forma

$$f(t) = \sum_k \sum_j c_{j,k} 2^{\frac{j}{2}} \phi(2^j t - kn) + \dots + \sum_k \sum_j d_{j,k} 2^{\frac{j}{2}} \psi(2^j t - kn)$$

Para representar una señal  $f(t)$  y teniendo en cuenta la ecuación (15), es necesario encontrar los valores de los coeficientes de escala ( $c_{j,k}$ ) y de los coeficientes wavelet ( $d_{j,k}$ ), los cuales permiten finalmente hacer la aproximación de la señal. Estos son producto de una multiplicación vectorial entre la función  $f(t)$  y la función de escala ( $\phi$ ) o wavelet ( $\psi$ ). Para estos coeficientes de escala se tiene:

$$c_{j,k} = \int_{t_1}^{t_2} f(t) \phi_{j,k}(2^j t - k) dt$$

$$d_{j,k} = \int_{t_1}^{t_2} f(t) \psi_{j,k}(2^j t - k) dt$$

El principal problema de la DWT radica en su dificultad para utilizarla en aplicaciones reales, por lo que se han desarrollado diferentes algoritmos que permiten realizar una aproximación a la transformada wavelet discreta, haciendo su empleo más fácil y generalizado en el ámbito del estudio de señales. Uno de estos métodos de aproximación de la DWT más conocidos es la descomposición wavelet packet, explicada en el siguiente capítulo.



### 2.2.6 DESCOMPOSICIÓN WAVELET PACKET

El análisis multirresolución, basado en la teoría wavelet, permite descomponer datos bidimensionales en componentes de distinta frecuencia y estudiar cada componente a una resolución acorde con su tamaño. A diferente resolución, el detalle de una imagen (componentes de alta frecuencia) caracteriza distintas estructuras físicas de la escena (Mallat 1989 [7]). A resoluciones groseras, este detalle corresponde a las estructuras o elementos de mayor tamaño mientras que a resoluciones finas, este detalle corresponde a las estructuras de menor tamaño. Las transformaciones wavelet permiten, en el ámbito del análisis multirresolución, extraer el detalle espacial que se pierde al pasar de una resolución espacial a otra menor. La aproximación discreta de la transformada wavelet puede realizarse a partir de distintos algoritmos.

Stephane Mallat ha desarrollado una implementación digital que convierte la Transformada Wavelet Discreta en una descomposición de la señal mediante un filtro paso alto (HP) y un filtro paso bajo (LP) [7]. El filtro *LP*, asociado a la función de escala, es un filtro paso bajo que permite analizar los componentes de baja frecuencia mientras que el filtro *HP*, asociado a la función wavelet, es un filtro paso alto que permite analizar los componentes de alta frecuencia. El número de parámetros de cada filtro así como el valor de los mismos depende de la función wavelet madre empleada en el análisis [15].

A partir de la señal original, se obtiene una salida para el filtro paso bajo, correspondiente a los valores de los coeficientes de escala (coeficientes de aproximación) (*c*), y otra para el filtro paso alto, relacionada con los coeficientes wavelet (denominados coeficientes de detalle) (*d*). En *d* se tiene una señal en el dominio temporal formada por los detalles de alta frecuencia de la señal.

Esta descomposición mediante los filtros paso alto *HP* y paso bajo *LP*, fracciona el espectro en dos bandas. A la salida del filtro *LP* se tiene una señal en el dominio del tiempo cuyo espectro está confinado entre 0 Hz y la mitad del espectro de la señal analizada. A su vez, la salida del filtro *HP* es una señal en el dominio del tiempo cuyo espectro está confinado entre la mitad del espectro y la frecuencia máxima de la señal. La salida del filtro paso alto da los detalles de las componentes de alta frecuencia, mientras que la salida del filtro paso bajo da las componentes de baja frecuencia. Esta salida (*c*) puede descomponerse de nuevo en el siguiente nivel de descomposición y así sucesivamente hasta repetir el proceso *n* veces, obteniéndose de esta forma una secuencia de filtros de descomposición wavelet denominada árbol simple y cuya representación aparece en la figura 2.6 [12].

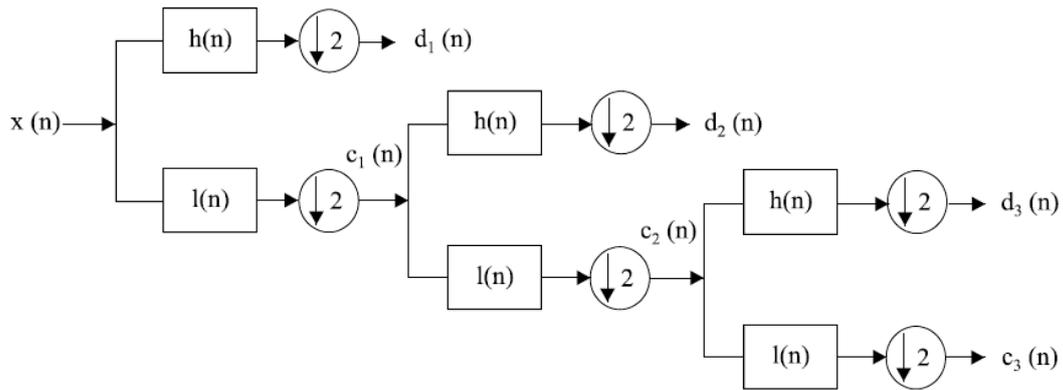


Figura 2.6: Árbol de descomposición wavelet simple de tres niveles [12].

A la salida de cada filtro y antes del siguiente nivel de descomposición se eliminan uno de cada dos coeficientes, lo que se denomina downsampling (submuestreo). Estos coeficientes son eliminados dado que no aportan información adicional en relación con el principio de incertidumbre, y se aumenta la resolución frecuencial, por lo que se disminuye en resolución temporal.

En las bandas con coeficientes de detalle podemos aplicar de nuevo la descomposición simple, de este modo estaremos diferenciando detalles más finos de entre otros más burdos, es decir, variaciones de mayor frecuencia de entre otras de frecuencia más baja. De este modo, se consigue una descomposición completa de la señal en bandas homogéneas. Esta descomposición de la salida de todos los filtros de niveles intermedios se denomina *Transformada Wavelet Packet* o *WPT* (del inglés *Wavelet Packet Transform*). Este conjunto de filtros se representa en la figura 2.7 y se denomina árbol de descomposición wavelet completo.

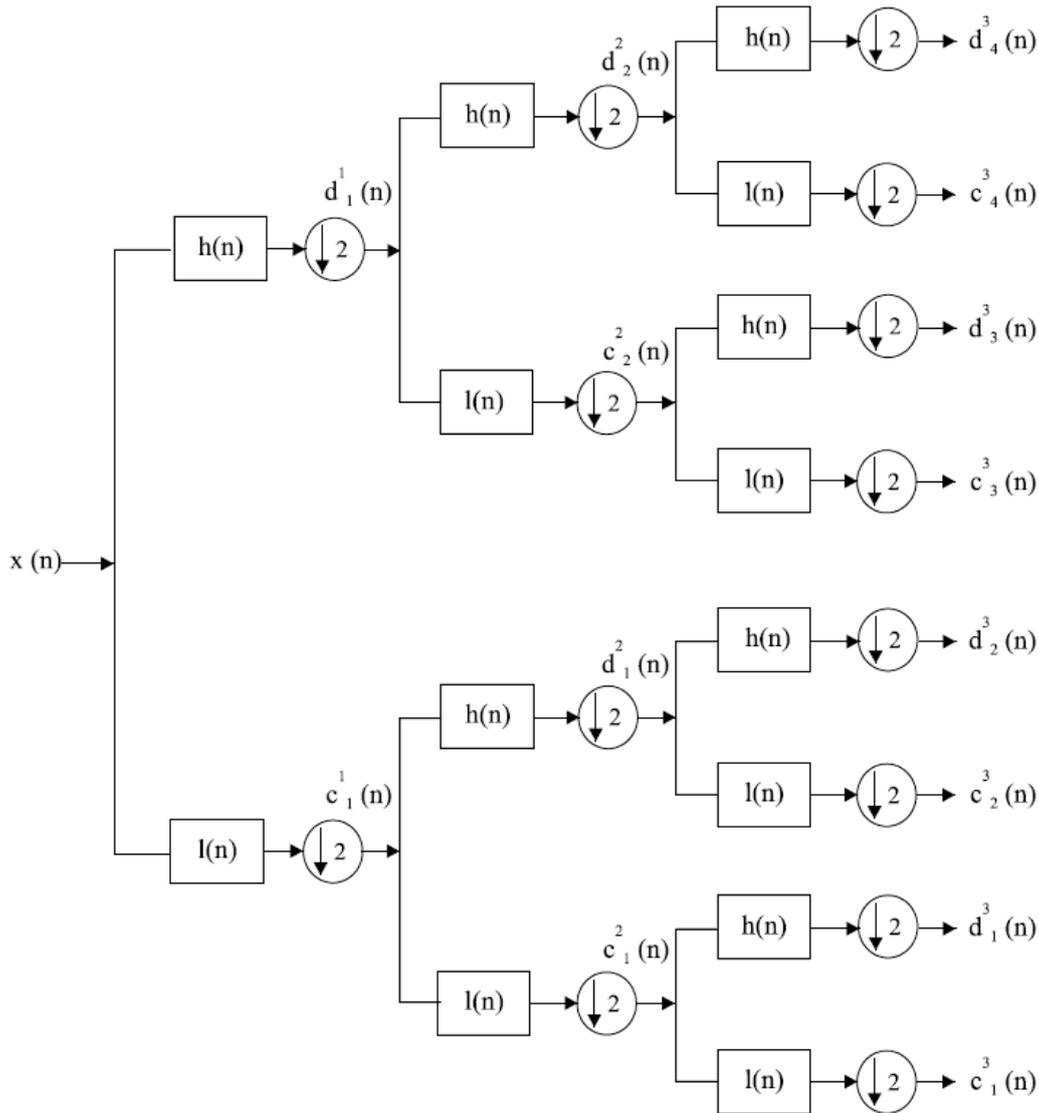


Figura 2.7: Árbol de descomposición wavelet completo de tres niveles [12].

A la salida de cada filtro se obtiene una señal temporal con su espectro confinado en una banda con frecuencias de corte definidas por las frecuencias de corte de los sucesivos filtros. Así, si la señal original ha sido muestreada con frecuencia  $f_s$ , entonces la mayor frecuencia que la señal muestreada puede representar es la frecuencia de Nyquist,  $f_s/2$ , de acuerdo con el Teorema del Muestreo [16]. Esto hace que la salida del filtro paso alto del primer nivel sea una señal con su contenido espectral dividido en dos bandas frecuenciales distintas de límites  $(0, f_s/4)$  y  $(f_s/4, f_s/2)$ . En cada nuevo nivel de descomposición vuelve a fraccionarse el espectro de salida de cada filtro del nivel anterior. Así, para el segundo nivel, tendremos a la salida de los filtros una señal con su contenido espectral fraccionado en bandas  $(0, f_s/8)$ ,  $(f_s/8, f_s/4)$ ,  $(f_s/4, 3f_s/8)$ ,  $(3f_s/8, f_s/2)$ . En el tercer nivel, las bandas frecuenciales de salida abarcan espectros comprendidos en los intervalos  $(0, f_s/16)$ ,  $(f_s/16, f_s/8)$ ,  $(f_s/8, 3f_s/16)$ ,  $(3f_s/16, f_s/4)$ ,  $(f_s/4, 5f_s/16)$ ,  $(5f_s/16, 3f_s/8)$ ,  $(3f_s/8, 7f_s/16)$ ,  $(7f_s/16, f_s/2)$ . Este ejemplo de bandas de frecuencias se corresponde con la descomposición wavelet de tres niveles mostrada en la figura 2.7



### 2.3 REDES NEURONALES

#### 2.3.1 INTRODUCCIÓN

En la bibliografía se pueden encontrar diferentes definiciones sobre lo que es una red neuronal, quizás la más completa es la siguiente [17]:

*“Una red neuronal artificial es un procesador distribuido en paralelo de forma masiva que tiene una tendencia natural para almacenar conocimiento de forma experimental y lo hace disponible para su uso”.*

Una red neuronal artificial se parece al cerebro humano en dos aspectos:

- El conocimiento es adquirido por la red a través de un proceso de aprendizaje.
- Los pesos sinápticos o fuerza con que están interconectadas las neuronas se utilizan para almacenar la información.

Otras definiciones que resultan de interés son:

- *“Una nueva forma de computación, inspirada en modelos biológicos”.*
- *“Un modelo matemático compuesto por un gran número de elementos procesales organizados en niveles”.*
- *“Un sistema de computación hecho por un gran número de elementos simples, elementos de proceso interconectados, los cuales procesan información por medio de su estado dinámico como respuesta a entradas externas”.*
- *“Redes neuronales artificiales son redes interconectadas masivamente en paralelo de elementos simples (usualmente adaptativos) y con organización jerárquica, las cuales intentan interactuar con los objetos del mundo real del mismo modo que lo hace el sistema nervioso biológico”.*

Aunque cada definición aporta información sobre lo que es una red neuronal, para saber cómo funcionan y en qué consisten es necesario desarrollar una explicación extensa.

En cuanto a las aplicaciones de las redes neuronales, hay que decir que pueden utilizarse en un gran número y variedad de campos, tanto comerciales como militares. Algunas aplicaciones comerciales son [18]:

- Biología: obtención de modelos de la retina.
- Empresa: evaluación de probabilidad de formaciones geológicas y petrolíferas, optimización del flujo del tránsito controlando convenientemente la temporización de los semáforos, modelado de sistemas para automatización y control.
- Medio ambiente: previsión del tiempo.



- Finanzas: previsión de la evolución de los precios, valoración del riesgo de los créditos, identificación de falsificaciones.
- Manufacturación: robots automatizados y sistemas de control (visión artificial y sensores de presión, temperatura, gas, etc.), inspección de la calidad.
- Medicina: diagnóstico y tratamiento a partir de síntomas y/o de datos analíticos (electrocardiograma, encefalogramas, análisis sanguíneo, etc.), entendimiento de la causa de los ataques cardíacos.
- Militares: clasificación de las señales de radar, creación de armas inteligentes.

La mayoría de estas aplicaciones consisten en realizar un reconocimiento de patrones, como pueden ser: buscar un patrón en una serie de ejemplos, clasificar patrones, completar una señal a partir de valores parciales o reconstruir el patrón correcto partiendo de uno distorsionado. Sin embargo, está creciendo el uso de redes neuronales en distintos tipos de sistemas de control.

### **2.3.2 HISTORIA DE LAS REDES NEURONALES**

En las siguientes líneas se presenta una breve exposición de los logros más importantes en lo referente al desarrollo de las redes neuronales que se han obtenido a lo largo de la historia [18].

1936 - Alan Turing. Fue el primero en estudiar el cerebro como una forma de ver el mundo de la computación. Sin embargo, los primeros teóricos que concibieron los fundamentos de la computación neuronal fueron Warren McCulloch, un neurofisiólogo, y Walter Pitts, un matemático, quienes, en 1943, lanzaron una teoría acerca de la forma de trabajar de las neuronas (Un Cálculo Lógico de la Inminente Idea de la Actividad Nerviosa - Boletín de Matemática Biofísica 5: 115-133). Ellos modelaron una red neuronal simple mediante circuitos eléctricos.

1949 - Donald Hebb. Fue el primero en explicar los procesos del aprendizaje (que es el elemento básico de la inteligencia humana) desde un punto de vista psicológico, desarrollando una regla de como el aprendizaje ocurría. Aun hoy, este es el fundamento de la mayoría de las funciones de aprendizaje que pueden hallarse en una red neuronal. Su idea fue que el aprendizaje ocurría cuando ciertos cambios en una neurona eran activados. También intentó encontrar semejanzas entre el aprendizaje y la actividad nerviosa. Los trabajos de Hebb formaron las bases de la Teoría de las Redes Neuronales.

1950 - Karl Lashley. En sus series de ensayos, encontró que la información no era almacenada en forma centralizada en el cerebro sino que era distribuida encima de él.

1956 - Congreso de Dartmouth. Este Congreso frecuentemente se menciona para indicar el nacimiento de la inteligencia artificial.



1957 - Frank Rosenblatt. Comenzó el desarrollo del Perceptron. Esta es la red neuronal más antigua; utilizándose hoy en día para aplicación como identificador de patrones.

1959 - Frank Rosenblatt: Principios de Neurodinámica. En este libro confirmó que, bajo ciertas condiciones, el aprendizaje del Perceptron convergía hacia un estado finito (Teorema de Convergencia del Perceptron).

1960 - Bernard Widroff/Marcian Hoff. Desarrollaron el modelo Adaline (ADaptative LINear Elements). Esta fue la primera red neuronal aplicada a un problema real (filtros adaptativos para eliminar ecos en las líneas telefónicas) que se ha utilizado comercialmente durante varias décadas.

1961 - Karl Steinbeck: Die Lernmatrix. Red neuronal para simples realizaciones técnicas (memoria asociativa).

1969 - Marvin Minsky/Seymour Papert. En este año casi se produjo la “muerte abrupta” de las Redes Neuronales; ya que Minsky y Papert probaron (matemáticamente) que el Perceptron no era capaz de resolver problemas relativamente fáciles, tales como el aprendizaje de una función no-lineal.

1974 - Paul Werbos. Desarrolló la idea básica del algoritmo de aprendizaje de *propagación hacia atrás* (backpropagation); cuyo significado quedó definitivamente aclarado en 1985.

1977 - Stephen Grossberg: Teoría de Resonancia Adaptada (TRA). La Teoría de Resonancia Adaptada es una arquitectura de red que se diferencia de todas las demás previamente inventadas. La misma simula otras habilidades del cerebro: memoria a largo y corto plazo.

1985 - John Hopfield. Provocó el renacimiento de las redes neuronales con su libro: “Computación neuronal de decisiones en problemas de optimización.”

1986 - David Rumelhart/G. Hinton. Redescubrieron el algoritmo de aprendizaje de *propagación hacia atrás* (backpropagation).

A partir de 1986, el panorama fue alentador con respecto a las investigaciones y el desarrollo de las redes neuronales. En la actualidad, son numerosos los trabajos que se realizan y publican cada año, las aplicaciones nuevas que surgen (sobre todo en el área de control) y las empresas que lanzan al mercado productos nuevos, tanto hardware como software (sobre todo para simulación).

### 2.3.3 EL MODELO BIOLÓGICO

La teoría y modelado de redes neuronales está inspirada en la estructura y funcionamiento de los sistemas nerviosos, donde la neurona es el elemento fundamental.

En general, una neurona consta de un cuerpo celular más o menos esférico, de 5 a 10 micras de diámetro, del que salen una rama principal, el axón, y varias ramas más cortas, llamadas dendritas, tal y como se muestra en la figura 2.8.

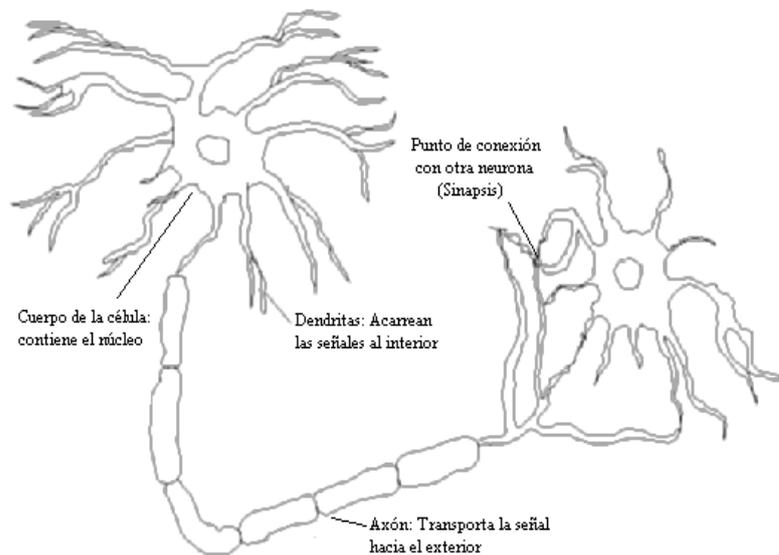


Figura 2.8: Neurona biológica [19].

Una de las características de las neuronas es su capacidad de comunicarse. En términos generales las dendritas y el cuerpo celular reciben señales de entrada; el cuerpo celular las combina e integra y emite señales de salida. El axón transmite dichas señales a los terminales axónicos, que distribuyen información a un nuevo conjunto de neuronas.

Para establecer una similitud directa entre la actividad sináptica y la analogía con las redes neuronales artificiales (véase figura 2.9) podemos considerar: las señales que llegan a la sinapsis son las entradas a la neurona; estas son ponderadas (atenuadas o simplificadas) a través de un parámetro, denominado peso asociado a la sinapsis correspondiente. Estas señales de entrada pueden excitar a la neurona (sinapsis con peso positivo) o inhibirla (peso negativo). El efecto es la suma de las entradas ponderadas. Si la suma es igual o mayor que el umbral de la neurona, entonces la neurona se activa (da salida). Esta es una situación de todo o nada; cada neurona se activa o no se activa.



Figura 2.9: Comparación entre una neurona biológica (izda.) y una artificial (dcha.) [19].

### 2.3.4 ELEMENTOS DE UNA RED NEURONAL ARTIFICIAL

Las redes neuronales artificiales (RNA) son modelos que intentan reproducir el comportamiento del cerebro. Como tal modelo, realiza una simplificación, averiguando cuáles son los elementos relevantes del sistema, bien porque la cantidad de información de que se dispone es excesiva o bien porque es redundante. Una elección adecuada de sus características, más una estructura conveniente, es el procedimiento convencional utilizado para construir redes capaces de realizar determinada tarea [19].

1. Unidad de proceso: la neurona artificial. Existen tres tipos de unidades en cualquier sistema que se distribuyen dentro de la red formando niveles o capas, cada una de ellas con un número determinado de neuronas. Estos tres tipos de unidades son las siguientes:

- *De entrada*: es la capa que recibe directamente la información proveniente de las fuentes externas de la red.
- *Ocultas*: son internas a la red y no tienen contacto directo con el entorno exterior. El número de niveles ocultos puede estar entre cero y un número elevado. Las neuronas de las capas ocultas pueden estar interconectadas de distintas maneras, lo que determina, junto con su número, las distintas topologías de redes neuronales.
- *De salida*: transfieren información de la red hacia el exterior.

En la figura 2.10 se puede ver el ejemplo de la estructura de una posible red multicapa, en la que cada nodo o neurona únicamente está conectada con neuronas de un nivel superior. Cabe destacar que pueden existir varias capas ocultas dentro de una red neuronal. Además, notar que hay más conexiones que neuronas en sí; en este sentido, se dice que una red es totalmente conectada si todas las salidas desde un nivel llegan a todos y cada uno de los nodos del nivel siguiente [18].

Cuando ninguna salida de las neuronas es entrada de neuronas del mismo nivel o de niveles precedentes, la red se describe como de propagación hacia adelante. Por el contrario, cuando las salidas pueden ser conectadas como entradas de neuronas de niveles previos o del mismo nivel, incluyéndose ellas mismas, la red es de propagación hacia atrás o retropropagación [19].

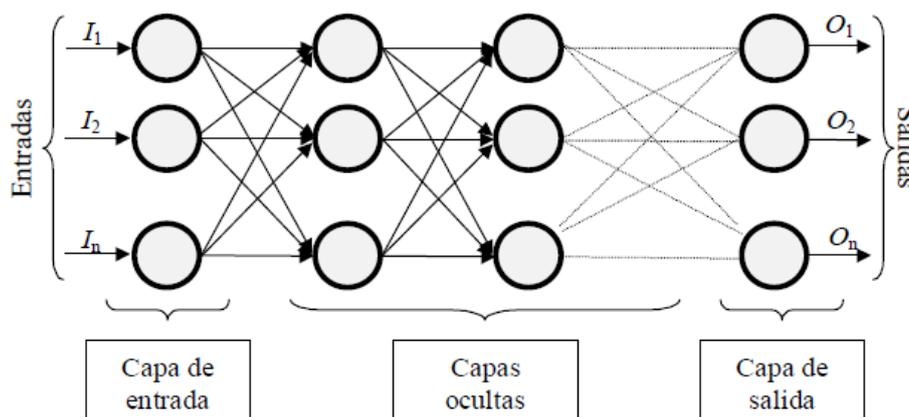


Figura 2.10: Ejemplo de una red neuronal totalmente conectada [18].



2. Estado de activación. Los estados del sistema en un tiempo  $t$  se representan por un vector  $A(t)$ . Los valores de activación pueden ser continuos o discretos, limitados o ilimitados. Si son discretos, suelen tomar un conjunto discreto de valores binarios, así un estado activo se indicaría con un 1 y un estado pasivo se representaría por un cero. En otros modelos se considera un conjunto de estados de activación, en cuyo valor entre  $[0,1]$ , o en el intervalo  $[-1,1]$ , siendo una función sigmoideal [19].
3. Función de salida o de transferencia. Asociada con cada unidad hay una función de salida, que transforma el estado actual de activación en una señal de salida.

Existen cuatro funciones de transferencia típicas que determinan distintos tipos de neuronas:

- Función escalón.
  - Función lineal y mixta.
  - Sigmoideal.
  - Función Gaussiana.
4. Conexiones entre neuronas. Las conexiones que unen a las neuronas que forman una RNA tienen asociadas un peso, que es el que hace que la red adquiera conocimiento. Se considera que el efecto de cada señal es aditivo, de tal forma que la entrada neta que recibe una neurona es la suma del producto de cada señal individual por el valor de la sinapsis que conecta ambas neuronas y es lo que se conoce como red de propagación. Se utiliza una matriz  $W$  con todos los pesos. Si  $w_{ji}$  es positivo indica que la relación entre las neuronas es excitadora, es decir, siempre que la neurona  $i$  esté activada, la neurona  $j$  recibirá una señal que tenderá a activarla. Si  $w_{ji}$  es negativo, la sinapsis será inhibitoria. En este caso si  $i$  está activada, enviará una señal que desactivará a  $j$ . Finalmente si  $w_{ji}$  es 0 se supone que no hay conexión entre ambas
  5. Función o regla de activación. Se requiere una regla que combine las entradas con el estado actual de la neurona para producir un nuevo estado de activación. Esta función  $F$  produce un nuevo estado de activación en una neurona a partir del estado que existía y la combinación de las entradas con los pesos de las conexiones. Esa  $F$  es denominada función de activación, y las salidas que se obtienen en una neurona para las diferentes formas de  $F$  serán:
    - Función de activación escalón.
    - Función de activación identidad.
    - Función de activación lineal –mixta.
    - Función de activación sigmoideal.



6. Regla de aprendizaje. El aprendizaje puede ser comprendido como la modificación de comportamiento inducido por la interacción con el entorno y como resultado de experiencias conduce al establecimiento de nuevos modelos de respuesta a estímulos externos. En el cerebro humano el conocimiento se encuentra en la sinapsis, mientras que, en el caso de las RNA, el conocimiento se encuentra en los pesos de las conexiones entre neuronas. Todo proceso de aprendizaje implica cierto número de cambios en estas conexiones. En realidad, puede decirse que se aprende modificando los valores de los pesos de la red.

### **2.3.5 CARACTERÍSTICAS DE LAS REDES NEURONALES**

Existen cuatro aspectos que caracterizan una red neuronal: su topología, el mecanismo de aprendizaje, tipo de asociación realizada entre la información de entrada y salida, y la forma de representación de estas informaciones [19].

#### **1. *Topología de las redes neuronales***

La arquitectura de las redes neuronales consiste en la organización y disposición de las neuronas formando capas más o menos alejadas de la entrada y salida de la red. En este sentido, los parámetros fundamentales de la red son: el número de capas, el número de neuronas por capa, el grado de conectividad y el tipo de conexiones entre neuronas.

En las redes monocapa: se establecen conexiones laterales, cruzadas o auto-recurrentes entre las neuronas que pertenecen a la única capa que constituye la red. Se utilizan en tareas relacionadas con lo que se conoce como auto-asociación; por ejemplo, para generar informaciones de entrada que se presentan a la red incompletas o distorsionadas.

Las redes multicapa son aquellas que disponen de conjuntos de neuronas agrupadas en varios niveles o capas. Una forma de distinguir la capa a la que pertenece la neurona, consiste en fijarse en el origen de las señales que recibe a la entrada y el destino de la señal de salida. Según el tipo de conexión, como se vio previamente, se distinguen las redes feedforward, y las redes feedforward/feedback.

#### **2. *Mecanismo de aprendizaje***

El aprendizaje es el proceso por el cual una red neuronal modifica sus pesos en respuesta a una información de entrada. Los cambios que se producen durante el proceso de aprendizaje se reducen a la destrucción, modificación y creación de conexiones entre las neuronas, la creación de una nueva conexión implica que el peso de la misma pasa a tener un valor distinto de cero, una conexión se destruye cuando su peso pasa a ser cero. Se puede afirmar que el proceso de aprendizaje ha finalizado cuando los valores de los pesos permanecen estables.



Un criterio para diferenciar las reglas de aprendizaje se basa en considerar si la red puede aprender durante su funcionamiento habitual, o si el aprendizaje supone la desconexión de la red.

Otro criterio suele considerar dos tipos de reglas de aprendizaje: las de aprendizaje supervisado y las correspondientes a un aprendizaje no supervisado. La diferencia fundamental entre ambos tipos estriba en la existencia o no de un agente externo (supervisor) que controle el aprendizaje de la red.

En las redes con aprendizaje supervisado, el proceso de aprendizaje se realiza mediante un entrenamiento controlado por un agente externo (supervisor, maestro) que determina la respuesta que debería generar la red a partir de una entrada determinada. El supervisor comprueba la salida de la red y, en el caso de que ésta no coincida con la deseada, se procederá a modificar los pesos de las conexiones, con el fin de conseguir que la salida se aproxime a la deseada. Se consideran tres formas de llevar a cabo este tipo de aprendizaje:

- Aprendizaje por corrección de error: consiste en ajustar los pesos en función de la diferencia entre los valores deseados y los obtenidos en la salida de la red; es decir, en función del error.
- Aprendizaje por refuerzo: se basa en la idea de no indicar durante el entrenamiento exactamente la salida que se desea que proporcione la red ante una determinada entrada. La función del supervisor se reduce a indicar mediante una señal de refuerzo si la salida obtenida en la red se ajusta a la deseada (éxito=+1 o fracaso=-1), y en función de ello se ajustan los pesos basándose en un mecanismo de probabilidades.
- Aprendizaje estocástico: este tipo de aprendizaje consiste básicamente en realizar cambios aleatorios en los valores de los pesos de las conexiones de la red y evaluar su efecto a partir del objetivo deseado y de distribuciones de probabilidad.

Respecto a las redes con aprendizaje no supervisado, éstas no requieren influencia externa para ajustar los pesos de las conexiones entre neuronas. La red no recibe ninguna información por parte del entorno que le indique si la salida generada es o no correcta, así que existen varias posibilidades en cuanto a la interpretación de la salida de estas redes.

En algunos casos, la salida representa el grado de familiaridad o similitud entre la información que se le está presentando en la entrada y las informaciones que se le han mostrado en el pasado. En otro caso podría realizar una codificación de los datos de entrada, generando a la salida una versión codificada de la entrada, con menos bits, pero manteniendo la información relevante de los datos, o algunas redes con aprendizaje no supervisado lo que realizan es un mapeo de características, obteniéndose en las neuronas de salida una disposición geométrica que representa un mapa topográfico de las características de los datos de entrada, de tal forma que si se presentan a la red informaciones similares, siempre sean afectadas neuronas de salidas próximas entre sí, en la misma zona del mapa. En general en este tipo de aprendizaje se suelen considerar dos tipos:

- Aprendizaje Hebbiano: consiste básicamente en el ajuste de los pesos de las conexiones de acuerdo con la correlación, así si las dos unidades son activas



(positivas), se produce un reforzamiento de la conexión. Por el contrario cuando una unidad es activa y la otra pasiva (negativa), se produce un debilitamiento de la conexión.

- Aprendizaje competitivo y cooperativo: las neuronas compiten (y cooperan) unas con otras con el fin de llevar a cabo una tarea dada. Con este tipo de aprendizaje se pretende que cuando se presente a la red cierta información de entrada, solo una de las neuronas de salida se active (alcance su valor de respuesta máximo). Por tanto las neuronas compiten por activarse, quedando finalmente una, o una por grupo, como neurona vencedora.

### **3. Tipo de asociación entre las informaciones de entrada y salida**

Las RNA son sistemas que almacenan cierta información aprendida; está información se registra de forma distribuida en los pesos asociados a las conexiones entre neuronas de entrada y salida. Existen dos formas primarias de realizar esa asociación de entrada/salida. Una primera sería la denominada heteroasociación, que se refiere al caso en el que la red aprende parejas de datos  $[(A_1, B_1), (A_2, B_2)... (A_n, B_n)]$ , de tal forma que cuando se presente cierta información de entrada  $A_i$ , deberá responder generándola correspondiente salida  $B_i$ . La segunda se conoce como auto-asociación, donde la red aprende ciertas informaciones  $A_1, A_2...A_n$ , de tal forma que cuando se le presenta una información de entrada realizará una autocorrelación, respondiendo con uno de los datos almacenados, el más parecido al de la entrada.

### **2.3.6 IMPLEMENTACIÓN DE LAS REDES NEURONALES**

En la búsqueda de sistemas inteligentes en general, se ha llegado a un importante desarrollo del software; dentro de esta línea se encuentran algunos de los neurocomputadores más conocidos. Un neurocomputador es básicamente un conjunto de procesadores conectados con cierta regularidad que operan concurrentemente. En la actualidad ya existen una serie de neurocomputadores comerciales destinados a la realización de redes neuronales [19].

La realización de redes neuronales más simple e inmediata consiste en simular la red sobre un ordenador convencional mediante un software específico. Es un procedimiento rápido, económico y fácilmente aplicable, pero su mayor desventaja radica en el hecho de que se intentan simular redes con un alto grado de paralelismo sobre máquinas que ejecutan secuencialmente las operaciones.

Otro método es la realización de redes neuronales a través de arquitecturas orientadas a la ejecución de procesos con un alto de paralelismo, tales como redes de transputers, arquitecturas sistólicas, etc. Este método es una optimización del anterior, ya que el acelera el proceso, permitiendo una respuesta en tiempo real, pero el comportamiento real de la red sigue siendo simulado por una estructura ajena a la estructura intrínseca de una red neuronal.



Una tercera aproximación radicalmente distinta es la realización de redes neuronales mediante su implementación por uno o varios circuitos integrados específicos. Son los llamados chips neuronales. Las neuronas y las conexiones se emulan con dispositivos específicos, de forma que la estructura del circuito integrado refleja la arquitectura de la red. Se consigue de esta forma realizaciones que funcionan a alta velocidad, pero a costa de una pérdida notable de velocidad.

### **2.3.7 VENTAJAS DE LAS REDES NEURONALES**

Debido a su constitución y a sus fundamentos, las RNA presentan un gran número de características semejantes a las del cerebro. Por ejemplo, son capaces de aprender de la experiencia, de generalizar de casos anteriores a nuevos casos, de abstraer características esenciales a partir de entradas que representan información irrelevante, etc. Esto hace que ofrezcan numerosas ventajas y que este tipo de tecnología se esté aplicando en múltiples áreas. Estas ventajas incluyen [19]:

#### **1. Aprendizaje adaptativo**

Una de las características más atractivas de las redes neuronales es la capacidad de aprender a realizar tareas basadas en un entrenamiento o una experiencia inicial.

Una RNA no necesita un algoritmo para resolver un problema, ya que ella puede generar su propia distribución de los pesos de los enlaces mediante el aprendizaje. La función del diseñador es únicamente la obtención de la arquitectura apropiada. No es problema del diseñador el cómo la red aprenderá a discriminar; sin embargo, si es necesario que desarrolle o seleccione un buen algoritmo de aprendizaje que proporcione la capacidad de discriminar de la red mediante un entrenamiento con patrones.

#### **2. Auto-organización**

Las redes neuronales usan su capacidad de aprendizaje adaptativo para organizar la información que reciben durante el aprendizaje y/o la operación. Una RNA puede crear su propia organización o representación de la información que recibe mediante una etapa de aprendizaje. Esta auto-organización provoca la facultad de las redes neuronales de responder apropiadamente cuando se les presentan datos o situaciones a los que no habían sido expuestas anteriormente.

#### **3. Tolerancia a fallos**

Comparados con los sistemas computacionales tradicionales, los cuales pierden su funcionalidad en cuanto sufren un pequeño error de memoria, en las redes neuronales, si se produce un fallo en un pequeño número de neuronas, aunque el comportamiento del sistema se vea influenciado, sin embargo no sufre una caída repentina.



Hay dos aspectos distintos respecto a la tolerancia a fallos: primero, las redes pueden aprender a reconocer patrones con ruido, distorsionados, o incompleta. Segundo, pueden seguir realizando su función (con cierta degradación) aunque se destruya parte de la red.

La razón por la que las redes neuronales son tolerantes a fallos es que tienen su información distribuida en las conexiones entre neuronas, existiendo cierto grado de redundancia en ese tipo de almacenamiento, a diferencia de la mayoría de los ordenadores algorítmicos y sistemas de recuperación de datos que almacenan cada pieza de información en un estado único, localizado y direccionable.

#### 4. Operación en tiempo real

Los computadores neuronales pueden ser realizados en paralelo, y se diseñan y fabrican máquinas con hardware especial para obtener esta capacidad.

#### 5. Fácil inserción dentro de la tecnología existente

Debido a que una red puede ser rápidamente entrenada, comprobada, verificada y trasladada a una implementación hardware de bajo costo, es fácil insertar RNA para aplicaciones específicas dentro de sistemas existentes (chips, por ejemplo).

### **2.3.8 REDES NEURONALES EMPLEADAS**

#### **2.3.8.1 Redes neuronales de reconocimiento de patrones**

Dentro de los diferentes tipos de redes neuronales usadas en el reconocimiento de patrones, nos centraremos en la empleada por el programa MATLAB® y su toolbox de redes neuronales y que es, por tanto, la que se ha utilizado en el presente proyecto. Dicha red neuronal consiste en una red feed-forward de dos capas, consistentes en una capa oculta con neuronas sigmoideas y una capa de salida.

Las redes *feed-forward* pueden considerarse unos aproximadores funcionales universales, es decir, una red con una única capa oculta, puede aproximar hasta el nivel deseado dentro de un conjunto compacto cualquier función continua. Las redes feed-forward son entrenadas habitualmente con el algoritmo de aprendizaje denominado *back-propagation* o BP, uno de los algoritmos con más importancia histórica en el desarrollo de las redes neuronales. Las redes neuronales asociadas a este algoritmo se definen como *redes back-propagation*. Los modelos más conocidos de este tipo de redes son *perceptron*, *adaline*, *madaline* y *linear adaptative memory*. En la figura 2.11 se muestra un ejemplo de la arquitectura de este tipo de redes [20].

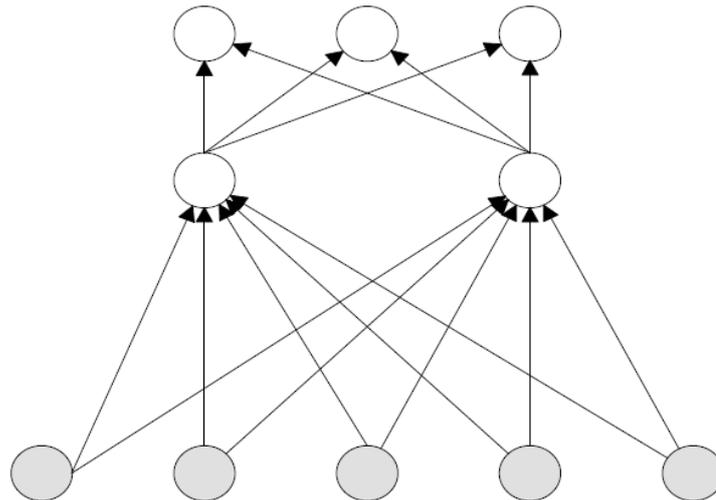


Figura 2.11: Ejemplo de red feed-forward multicapa [20].

Es importante mencionar que las redes *feed-forward* son las más sencillas en cuanto a implementación y simulación, pero su desempeño es bueno para aplicaciones en las que no se requiera que la red retenga información de eventos pasados como ayuda para evaluar eventos futuros.

Al iniciar las investigaciones sobre redes neuronales, las redes *feedforward* fueron las que recibieron más atención porque sus características en cuanto a tiempos de procesamiento hacían viables simulaciones con los equipos computacionales de la época, puesto que su balance costo-velocidad y costo-exactitud es tal que da mayor ventaja al costo que a los otros parámetros [21].

Los factores que influyen en el proceso de aprendizaje del algoritmo back-propagation (BP) son, entre otros:

- Los *pesos iniciales* que son normalmente inicializados de forma aleatoria, pero existen otras posibilidades, como por ejemplo,  $(-3/\sqrt{k_i}, 3/\sqrt{k_i})$  donde " $k_i$ " es el número de conexiones entre inputs y neuronas en la capa oculta.
- La *constante de aprendizaje*, factor de gran importancia en el proceso de convergencia, tanto en lo referente a cómo afecta su valor, como cuál es el mejor valor a utilizar en las aplicaciones.
- Las *funciones de coste*, usualmente se utiliza la función cuadrática.
- El *momentum*, filtrado de paso bajo (alisado) del gradiente del error.
- Técnicas de optimización utilizadas, métodos de *gradiente descendente*, método de *Newton*, método de *quasi-Newton*, método de *dirección conjugada*.
- Aprendizaje y generalización.
- *Número de neuronas* en las capas ocultas.



Dado un conjunto de observaciones, la tarea del aprendizaje neuronal es construir un estimador  $g_\lambda(x, w)$  de la función desconocida  $h(x)$  del cual se conoce sólo un conjunto de datos,

$$g_\lambda(x, w) = \gamma_2 \left( \sum_{j=1}^{\lambda} w_j^{[2]} \gamma_1 \left( \sum_{i=1}^m w_{ij}^{[1]} x_i + w_{m+1,j}^{[1]} \right) + w_{\lambda+1}^{[2]} \right)$$

donde  $w = (w_1, \dots, w_d)^T$  es el vector paramétrico a ser estimado y equivale a las ponderaciones de las conexiones entre las neuronas de la red,  $\gamma_1$  es una función no-lineal acotada y diferenciable con forma de función sigmoide o de radio basal,  $\gamma_2$  es una función que puede ser lineal o no lineal y  $\lambda$  es el parámetro de control que indica el número de neuronas escondidas [22].

La función  $\gamma_1$  típicamente es la función sigmoide dada por

$$\gamma_1(z) = \frac{1}{1 + e^{-z}}$$

Si la función  $\gamma_2$  se elige no-lineal, debe ser estrictamente monótona, acotada y diferenciable. La función sigmoide satisface estos requisitos.

El ajuste de la red se produce como resultado de la estimación de los parámetros basado en una muestra de tamaño  $n$ . La estimación es obtenida minimizando una función de costo es decir:

$$w_n^{LS} = \arg \min \{L_n(w) : w \in W \subseteq \mathcal{R}^d\}$$

donde  $L_n(w)$  normalmente viene dado por la función del promedio de los errores al cuadrado entre el dato estimado por la red y el dato real, es decir:

$$L_n = \frac{1}{2n} \sum_{t=1}^n (y_t - g(x^t, w))^2$$

**2.3.8.2 Redes neuronales de función de base radial (RBF)**

Las redes de función de base radial (RBF) son en este momento uno de los modelos más utilizados debido a su rápida formación, generalidad y simplicidad. Se trata de un modelo híbrido, ya que incorpora tanto el aprendizaje supervisado como el no supervisado. La parte no supervisada se sitúa desde el vector de inputs a la capa oculta, donde debe decidirse el número de nodos radiales que cubran buena parte del espacio definido por los inputs o entradas y la parte supervisada desde la capa oculta y la capa del output. Los modelos Radial Basis (RBF) normalmente se comparan con los modelos feed-forward (MLP), pero aún siendo los más utilizados, poseen serios problemas que en la mayoría de los casos los modelos RBF solucionan, como por ejemplo la rapidez en el aprendizaje o proceso de estimación. La arquitectura de un modelo neuronal con funciones de base radial o RBF posee tres capas, de



entrada, oculta y capa de salida, muy parecida al modelo MLP<sup>1</sup> ya estudiado en el apartado 2.3.8.1 y cuya expresión es [20]:

$$y = \beta_0 + \sum_{j=1}^q \beta_j g_j(x_i) + \varepsilon$$
$$g_j(x_i) = \exp\left(-\frac{\sum_{j=1}^q (x_i - \mu_j)^2}{2\sigma_j^2}\right)$$
$$X = (x_1, x_2, \dots, x_p)'$$
$$\{\beta_j, j = 0, 1, \dots, q\}$$

donde, la función  $g_j(x_i)$  es una de las posibles funciones radiales, la función gaussiana. Pero existen otras muchas posibilidades, como por ejemplo,

$$g(x_i) = \left(\sum_{j=1}^q (x_i - \mu)^2 + \sigma^2\right)^2, \quad \alpha > 0$$

que posee las mismas cualidades de localización. También existen otras funciones que no cumplan dicha propiedad, como por ejemplo el caso cúbico y la función lineal.

Podemos comprobar que en todos los casos, previamente al diseño de la función radial, existe la definición de una distancia estadística, habitualmente la euclídea, que separa el vector de *inputs* y el centroide. Así, si el vector de *inputs* coincide con el centroide de la neurona oculta  $j$ , ésta responde con el máximo valor, es decir, la unidad. El parámetro, “ $\sigma$ ” o factor de escala mide la anchura de la función *gaussiana* y se puede definir como el área de influencia de la neurona en el espacio de los *inputs*. A mayor valor, la región que la neurona oculta domina, cerca del centroide es más amplia, (véase ilustración 2.12).

---

<sup>1</sup> La diferencia esencial está en la operación que se produce en la capa oculta. Así en el caso MLP se calcula la suma ponderada de los *inputs* y posteriormente se le aplica una función de transferencia, en cambio en los modelos RBF, opera sobre la base de la distancia que separa el vector *inputs* respecto del vector *centroide* almacenado en cada neurona oculta (de la misma forma que el modelo no supervisado de Kohonen). Posteriormente al resultado anterior se le aplica una *función radial*, véase Martín del Brío, B ; Sanz Molina, A. (1997). **Redes Neuronales y sistemas borrosos**, pp. 152-158, Ra-Ma, Madrid.

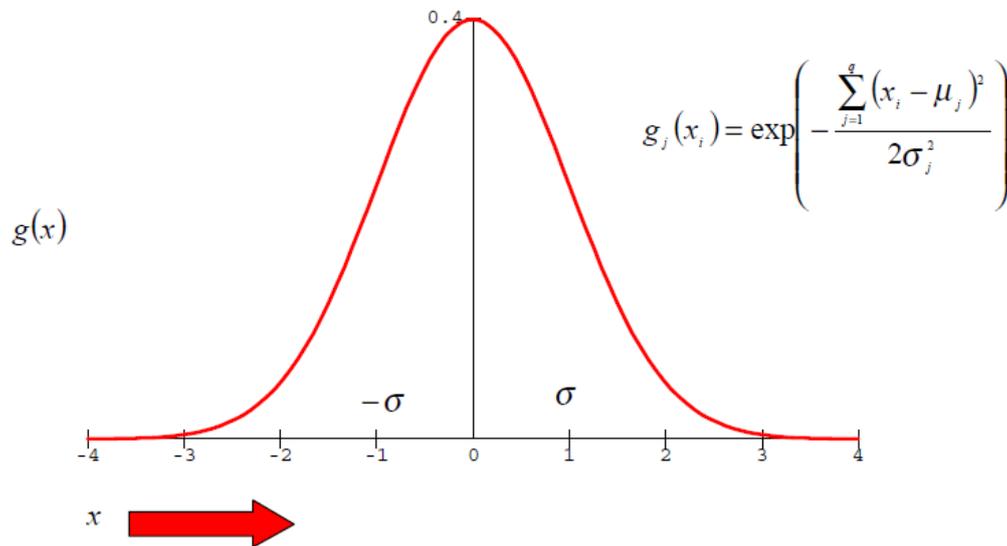


Figura 2.12: Representación de una función de base radial [20].

La elección del número de nodos radiales, es decir, la parte no supervisada, debe tener en cuenta el compromiso entre el error que se comete y su capacidad de generalización. Existen procedimientos para automatizar dicho aspecto, como por ejemplo, el *algoritmo autoorganizado jerárquico* que evalúa la necesidad de incrementar el número de nodos en función de su nivel de activación. El proceso habitual es un aprendizaje por etapas, en la primera de ellas, se determinan el número de nodos y el cálculo de los *centroides*. En la segunda etapa, se calculará el parámetro de escala, "j  $\sigma$ ", donde su estimación se suele realizar por métodos heurísticos. Finalmente, en la última etapa y mediante el aprendizaje supervisado se entrenará el modelo en la capa de salida. Este carácter híbrido consigue acelerar notablemente el entrenamiento respecto al modelo neuronal MLP, (véase ilustración 2.13).

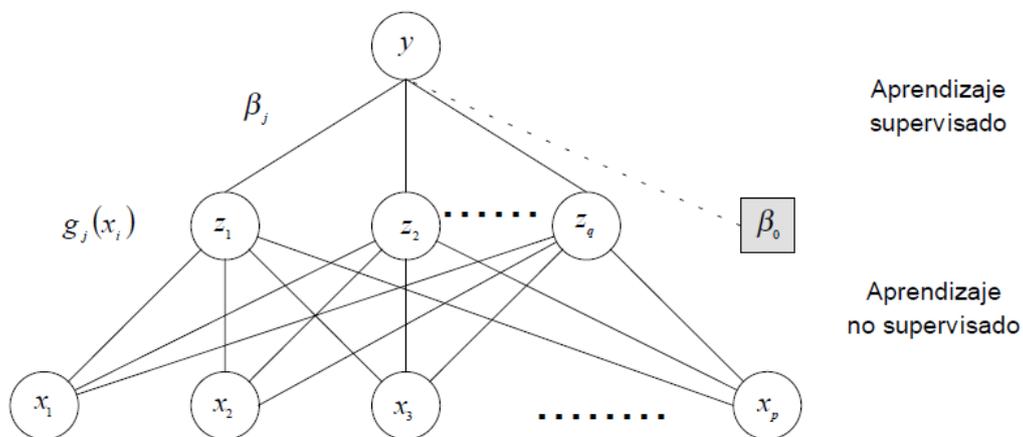


Figura 2.13: Modelo neuronal RBF [20].

Existen algunos aspectos relevantes de dichos modelos que son de interés. Primeramente, las relaciones existentes entre los modelos RBF y otras formas de aproximar



funciones, como por ejemplo, la *regresión de kernel*. En segundo lugar, la aplicación de los mismos a tareas de clasificación, muy próximos a los modelos probabilísticos neuronales. En tercer lugar, la aplicación de técnicas de mínimos cuadrados ortogonales para la selección de los *centroides* de las áreas de influencia y finalmente, las funciones radiales pueden ser especificadas como las componentes de modelos mixtos de densidad, cuyos parámetros son optimizados por máxima verosimilitud.

### **2.3.8.3 Redes neuronales probabilísticas (PNN)**

Los modelos neuronales probabilísticos (*probabilistic neural networks*, PNN) surgen en los años 70 y fueron descritos por Meisel (1972). Pero no empezaron a tener importancia hasta los años 90 con Specht. Dichos modelos aparecen de forma natural en el marco de la teoría de la probabilidad y son en esencia un clasificador *bayesiano*. Desde esta óptica y con un perfil clásico, los algoritmos de clasificación asumen el conocimiento de la distribución de las variables aleatorias que se utilizan para clasificar. Pero en la mente de todos está la idea de la problemática que ocasiona en los análisis, la existencia de mayores desviaciones o la aparición de distribuciones multimodales. Con el objetivo de clasificar también pueden ser utilizados los modelos *feed-forward*, aunque adolecen de ciertos problemas. Según Master (1995), la primera de las dificultades radica en su forma de operar y la segunda, en el desconocimiento de cuál es el comportamiento teórico esperado [20].

Las PNN poseen por su parte tres limitaciones. Su lentitud en clasificar, un alto coste computacional y una elevada necesidad de memoria de sistema. Pero a su favor juega su alta resistencia y estabilidad frente la presencia de *outliers*. Los modelos probabilísticos, tal y como se ha comentado, utilizan la metodología de *Bayes* para su proceso de clasificación, pero de forma habitual se desconocen las funciones de densidad necesarias para su aplicación. En este entorno los métodos de estimación existentes son los siguientes. El primero de ellos es el *paramétrico*, donde se parte de la definición de una forma funcional específica que posee un número limitado de parámetros ajustables.

En segundo lugar, existe otra forma de aproximación al problema, los denominados métodos secuenciales de estimación basados en técnicas iterativas, como por ejemplo, los procedimientos de aproximación estocástica o de Robbins-Monro (1951). Y en último lugar, los métodos *no paramétricos*, que no especifican a priori la forma funcional de la función de densidad. Ésta se obtiene de los propios datos observados y existen varias aproximaciones para poder estimar la función de densidad de forma no paramétrica. Por ejemplo, el método del *histograma*, que en esencia es un método semiparamétrico consistente en representar la función de densidad desconocida mediante un "histograma", aumentando progresivamente el número de intervalos definidos, los métodos basados en *Kernel* y en tercer lugar, el método de *k-nearest-neighbours*.

Todos los métodos anteriores no paraméricos necesitan la definición de un parámetro de gran importancia que dirige el proceso de adaptación a los datos, denominado *smoothing parameter*. Ahora bien, existen métodos que combinan las ventajas de los métodos paraméricos y no paraméricos, los llamados modelos *mixtura*, cuyo modelo más conocido es



el modelo mixtura *Gaussiano*, muy cercano a los modelos RBF del apartado 2.3.8.2 y posee aplicaciones en el campo actuarial.

El teorema de *Bayes*, que es parte fundamental del desarrollo de los modelos neuronales *probabilísticos*, posee la siguiente expresión,

$$P(y^i|X) = \frac{P(X|y^i)P(y^i)}{P(X)}$$

siendo,

$P(X|y^i)$  : probabilidad de que el vector de entrada  $X$  esté en la clase  $y^i$ ,

$P(y^i)$  : probabilidad que se produzca la clase "i",

$P(X)$  : probabilidad de un vector de entrada con valor  $X$ ,

$P(y^i|X)$  : probabilidad a posteriori de  $y^i$ .

En los modelos PNN el cálculo de la probabilidad condicionada,  $P(X|y^i)$ , se aproxima mediante las ventanas *Parzen*, normalmente utilizando una función exponencial.

$$P(X|y^i) = \left( \frac{1}{n^i (2\pi^{(p/2)} \sigma^p)} \right) \sum_{j=1}^{n^i} e^{(-D_j^2 / (2\sigma^2))}$$

siendo,

$D_j^2 = \sum_{j=1}^{n^i} (x_i - \mu_j)^2$  : distancia *Euclídea* al cuadrado en cada una de las  $i$ -clases definidas<sup>2</sup>,

$k = \left( \frac{1}{(2\pi^{(p/2)} \sigma^p)} \right)$  : factor de escala,

$n^i$  : número de neuronas en la capa oculta para cada una de las  $i$ -clases definidas siendo  $n$  el total de las mismas,

$p$  : número de inputs en el vector de entrada,  $X=(x_1, x_2, \dots, x_p)'$ .

Además, la probabilidad  $P(y^i) = (n^i/n)$  es estimada como la frecuencia relativa del número de neuronas en la capa oculta segmentada para las  $i$ -clases. Si ahora aplicamos el teorema de Bayes para calcular la probabilidad condicional de "X" para cada  $i$ -clase tenemos,

$$P(X) = \sum_{i=1}^n \left( \frac{1}{n^i (2\pi^{(p/2)} \sigma^p)} \right) \sum_{j=1}^{n^i} e^{(-D_i^2 / (2\sigma^2))(n^i/n)}$$

<sup>2</sup> Dicha expresión es muy similar a la definida para el modelo neuronal *RBF*, apartado 2.5.5.2., excepto en los siguientes aspectos: en primer lugar, por el factor de escala, "  $k$  ", en segundo lugar, las neuronas de la capa oculta se dividen en el número de clase predefinidas y en tercer lugar, todas las ponderaciones entre capas son unitarias.

sustituyendo las expresiones anteriores en el teorema de Bayes, tenemos la probabilidad condicional,

$$P(y^i|X) = \frac{\sum_{j=1}^{n_i} e^{(-D_j^{i^2}/(2\sigma^2))}}{\sum_{j=1}^n e^{(-D_i^2/(2\sigma^2))}}$$

donde, en primer lugar, cada valor que genera el modelo representa la probabilidad condicional de una  $i$ -clase, dado el vector de *inputs*. En segundo lugar, las neuronas de la capa oculta se segmentan según las clases definidas y en último lugar, el numerador de la expresión anterior sólo se adiciona en función de la clase que pertenece la neurona oculta respectiva, (véase ilustración 2.14).

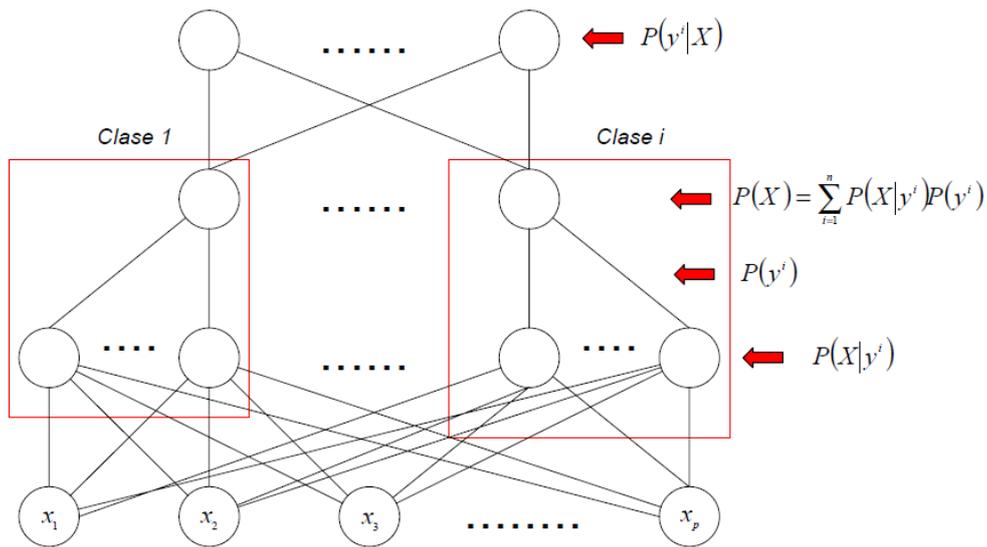


Figura 2.14: Topología de un modelo neuronal PNN [20].

En último lugar, existen avances desde la óptica de la construcción de algoritmos de aprendizaje para los modelos PNN, donde no es necesario definir a priori la topología necesaria.



## Capítulo 3:

### Descripción del sistema experimental



## 3. DESCRIPCIÓN DEL SISTEMA EXPERIMENTAL

En este tercer capítulo se ofrece una exposición detallada sobre la máquina de ensayos empleada en el presente proyecto para el estudio y posterior adquisición de los datos necesarios para su implementación en redes neuronales. Por otra parte, también se presentarán cada uno de los diferentes elementos que intervienen en la adquisición de los datos, como pueden ser el sistema de medida formado por el acelerómetro y los filtros de acondicionamiento de la señal empleados para el desarrollo del proyecto. Pero, antes de empezar a explicar cada uno de los distintos elementos, será necesario integrarlos dentro del sistema tal y como se puede apreciar en la figura 3.1.

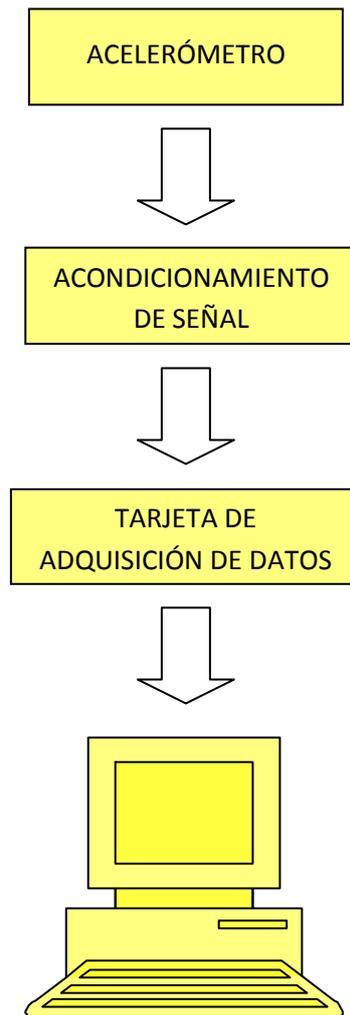


Figura 3.1: Esquema de las conexiones entre los aparatos de medida.



### 3.1 MÁQUINA DE ENSAYOS

#### 3.1.1 INTRODUCCIÓN

La máquina de ensayos empleada denominada Rotokit ha sido fabricada por la empresa Spectra Quest, Inc. y permite realizar diferentes ensayos de ejes y rodamientos de diámetros y longitudes pequeñas (2.5 cm de diámetro aproximadamente). Además, esta máquina permite la instalación de kits de accesorios específicos para efectuar otro tipo de estudios. El Rotokit permite realizar ensayos relacionados con [23]:

- Comportamiento de ejes fisurados.
- Resonancia y velocidad crítica.
- Comportamiento de un eje ante diferentes configuraciones.
- Estudios de rodamientos con defectos.
- Alineamientos.
- Balanceo.
- Cajas de engranajes.
- Correas.

El Rotokit permite realizar los ensayos a distintas velocidades de rotación controladas de forma manual o bien, programar diferentes tipos de rampas controladas de manera automática. Esto último permite simular el comportamiento del elemento en estudio, bien sea un eje o bien un rodamiento, ante un arranque como el que tendría lugar en cualquier máquina a la que estuviese destinado el elemento en cuestión.

En lo que respecta al diseño del Rotokit, cabe decir que se trata de una máquina de ensayos muy sencilla en cuanto a construcción se refiere, tal y como puede apreciarse en la figura 3.2. Dicha máquina consta de una bancada sobre la que se apoyan diferentes elementos fijos, como puede ser el motor, y los elementos objeto de estudio como pueden ser ejes o rodamientos.

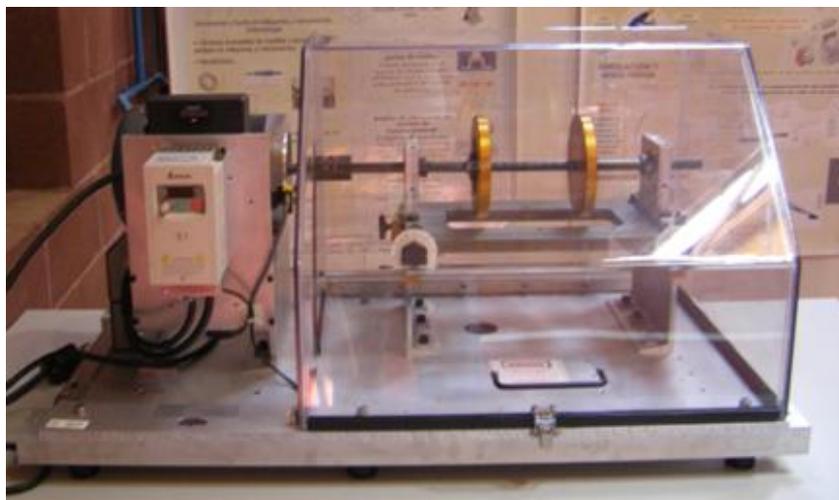


Figura 3.2: Imagen de la máquina de ensayos Rotokit.



La instalación de los ejes y rodamientos es muy simple, puesto que sólo hay que soltar unas sujeciones laterales para su colocación en la máquina. Estas sujeciones van atornilladas a la bancada mediante tornillos de cabeza tipo Allen, evitando movimientos verticales y horizontales de los rodamientos durante el ensayo. También cuenta con un acoplamiento entre el motor y el eje que transmite el movimiento generado por el motor al eje y evita la introducción de vibraciones provenientes del primero que puedan interferir en la toma de datos realizadas.

### **3.1.2 MOTOR**

La máquina de ensayos Rotokit cuenta con un motor de la marca MARATHON, concretamente el modelo 56T34F5301 J, mostrado en la figura 3.3. Éste es un motor de propósito general que puede emplearse en diferentes configuraciones de montaje, siendo adecuado para aplicaciones comerciales tales como reductores, bombas y máquinas herramienta y otros equipos donde va acoplado directamente en ambientes polvorientos y sucios [24].



Figura 3.3: Motor MARATHON 56T34F5301 J.

El motor MARATHON presenta un factor de servicio de 1.15 con un sistema de aislamiento clase F y con rodamientos de bolas. Las características principales de este motor se presentan en la tabla 3.1:

Potencia (W)	246
Velocidad (rpm)	3000
Voltaje (V)	190/380
Corriente (A)	1.85/0.92
Rendimiento (%)	62
Peso (kg)	10
Par (N)	1.03
Corriente en vacío (A)	1.4/0.7

Tabla 3.1: Características del motor MARATHON 56T34F5301 J.



### 3.1.3 VARIADOR DE FRECUENCIA

La máquina de ensayos Rotokit está controlada por un variador de frecuencia Delta VFD 007S21B, mostrado en la figura 3.4, que permite controlar la velocidad del el motor y realizar ensayos como puede ser la ejecución de cierto tipo de rampas de arranque [25].



Figura 3.4: Variador de frecuencia Delta VFD 007S21B.

Los variadores de frecuencia fabricados por Delta están provistos de modernos controles con microprocesador que emplean modulación en alta frecuencia del ancho de pulso de la fuente de poder para lograr una marcha suave en el motor. La serie Delta VFD emplea la tecnología electrónica de núcleo, bien reconocida dentro del sector de la automatización. Las características principales del variador de frecuencia empleado se muestran en la tabla 3.2:

Salida máxima aplicable para el motor (kW)		0.75
Características de salida	Capacidad de salida nominal (kVA)	1.6
	Corriente da salida nominal (A)	4.2
	Tensión máxima de salida (V)	3 fases proporcional al voltaje de entrada
	Frecuencia de salida (Hz)	0.1-400 Hz
	Frecuencia del transportador (kHz)	3-10
Características de entrada	Corriente de entrada (A)	Monofásico / Trifásico 9.7/5.1
	Monofásico (corriente de entrada trifásica)	5.1
	Voltaje / Frecuencia	Monofásico/Trifásico 200-240V, 50/60Hz
Tolerancia de tensión		±10% (180 – 264 V)
Tolerancia de frecuencia		±5% (47 – 63 Hz)
Método de enfriamiento		Enfriamiento natural
Peso (Kg)		1.5

Tabla 3.2: Características del variador de frecuencia Delta VFD 007S21B.



También se dispone de un tacómetro digital, situado sobre el variador de frecuencia, que muestra la velocidad de giro del eje en rpm o, si se programa adecuadamente, puede mostrar dicha velocidad en Hz. Este tacómetro emplea un sensor óptico consistente en una cinta reflectante situada sobre el eje del motor [26].

### **3.1.4 SEGURIDAD**

Por último, el Rotokit cuenta con una mampara de seguridad que protege al usuario frente a cualquier impacto que pueda originarse en el transcurso de un ensayo, como puede ser una rotura de un eje, así como también evita que haya accidentes por la invasión de la zona de trabajo de la máquina. Dicha mampara posee, además, un cerrojo que impide su apertura accidental ante cualquier fallo [26].

También hay que considerar ciertas precauciones de seguridad para el correcto funcionamiento del Rotokit, tales como:

1. No someter la máquina de ensayos a vibraciones excesivas durante un largo periodo de tiempo.
2. Evitar superar el 20% de la velocidad crítica de diseño por un tiempo mayor de 30 segundos en cada uso.
3. No sobrepasar la velocidad de 6000 rpm (aplicable para simuladores de corriente alterna) por un tiempo mayor de 30 segundos.

## 3.2 CADENA DE MEDIDA

### 3.2.1 ACELERÓMETRO

#### 3.2.1.1 Introducción

Las técnicas convencionales para detectar y medir la aceleración se fundamentan en el primer principio descubierto por Newton y descritos en su *Principio de Newton* en 1687. La aceleración constante de una masa implica una fuerza ( $F = m \cdot a$ ), donde  $F$  es la fuerza,  $a$  es la aceleración y  $m$  es la masa.

Muchos acelerómetros operan detectando la fuerza ejercida en una masa por una limitación elástica (ver figura 3.5).

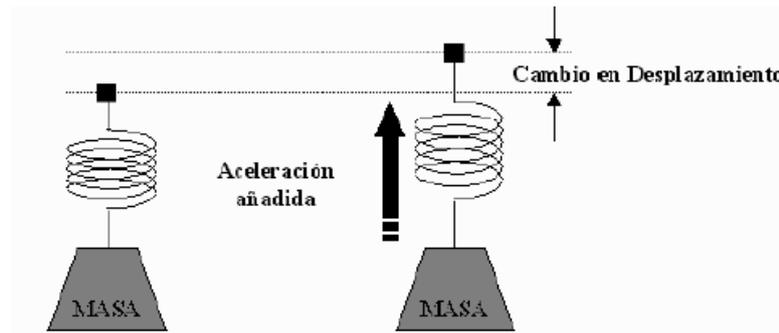


Figura 3.5: Esquema de un sistema mecánico simple en el que se basa el funcionamiento de los acelerómetros [27].

Considerando un sistema mecánico simple como el mostrado en la figura 3.3, que consiste en una masa fija  $m$ , con un muelle con una rigidez  $k$  (constante), si la masa se desplaza una distancia  $x$ , la aceleración debida a la fuerza restauradora del muelle es

$$F = k \cdot x$$

Sustituyendo en la ecuación de Newton, se obtiene que

$$a = k \cdot x / m$$

y se puede derivar la magnitud de la aceleración observando el desplazamiento  $x$  de la masa fija. Este principio fundamental se utiliza hasta en el más sofisticado y caro acelerómetro electromecánico; así también trabajan los modernos acelerómetros micromecanizados.

La aceleración es el cambio de la velocidad y la unidad de medida es:  $m/s^2$ ,  $g$  ( $1g=9.81 m/s^2$ ).

En los últimos tiempos, la medida de la aceleración es muy utilizada por las excelentes prestaciones de los sensores desarrollados para ser aplicados en sistemas de seguridad en automoción como en el caso del airbag. Los primeros sensores de aceleración eran unos sistemas muy complejos y no muy fiables que se basaban en la medida de los desplazamientos



de una masa inercial sujeta a la aceleración con resortes que contrarrestaban el efecto de la fuerza generada por la masa.

Otras variables que llevan implícita la medida de la aceleración son los sensores de impacto que se caracterizan por la detección de fuertes aceleraciones en cortos períodos de tiempo como en el caso de los sensores de choque que disparan los airbag.

Los sensores utilizados para medir la aceleración se denominan acelerómetros. Los acelerómetros son sensores inerciales que miden la segunda derivada de la posición. Un acelerómetro mide la fuerza de inercia generada cuando una masa es afectada por un cambio de velocidad. En la figura 3.6 se puede ver un esquema básico de la construcción de un acelerómetro [27].

Esta fuerza puede variar:

- La tensión de un muelle.
- La deformación de un elemento.
- La frecuencia de vibración de una masa.

Elementos:

- Masa.
- Mecanismo de suspensión.
- Sensor.

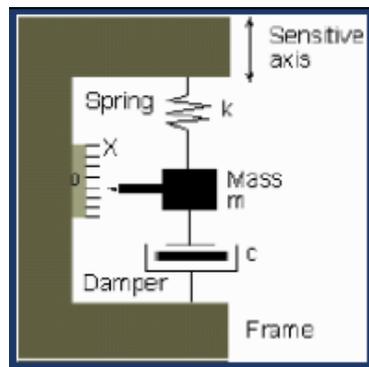


Figura 3.6: Esquema con los diferentes elementos de los que consta un acelerómetro [27].

$$F = m \frac{d^2 x}{dt^2} + c \frac{dx}{dt} + kx$$

Los de alta calidad incluyen realimentación para mejorar la linealidad.



### **3.2.1.2 Tipos de acelerómetros**

A continuación se presenta una breve introducción de las diferentes clases de acelerómetros que existen, explicando también sus características.

#### **- *Acelerómetros mecánicos***

Este tipo de acelerómetros emplean una masa inerte y resortes elásticos. Los cambios se miden con galgas extensiométricas, incluyendo sistemas de amortiguación que evitan la propia oscilación. También se emplean sistemas rotativos desequilibrados que originan movimientos oscilatorios cuando están sometidos a aceleración (servoacelerómetros) o detectan el desplazamiento de una masa inerte mediante cambios en la transferencia de calor (acelerómetros térmicos).

#### **- *Acelerómetros capacitivos***

Modifican la posición relativa de las placas de un microcondensador cuando está sometido a aceleración. El movimiento paralelo de una de las placas del condensador hace variar su capacidad. Los acelerómetros capacitivos basan su funcionamiento en la variación de la capacidad entre dos ó más conductores entre los que se encuentra un dieléctrico, en respuesta a la variación de la aceleración.

Los sensores capacitivos en forma de circuito integrado en un chip de silicio se emplean para la medida de la aceleración. Su integración en silicio permite reducir los problemas derivados de la temperatura, humedad, capacidades parásitas, terminales, alta impedancia de entrada, etc.

#### **- *Acelerómetros piezoeléctricos***

Su funcionamiento se basa en el efecto piezoeléctrico, por el que una deformación física del material causa un cambio en la estructura cristalina y así cambian las características eléctricas. Su principal inconveniente radica en su frecuencia máxima de trabajo y en la incapacidad de mantener un nivel permanente de salida ante una entrada común.

Los fabricantes suelen utilizar una serie de materiales piezoeléctricos que mediante la adición de masas pueden actuar como sensores de aceleración, ya que añadiendo una masa,  $F = m \cdot a$ .

A la hora de utilizar este tipo de sensores para medir la aceleración podemos encontrar diversos tipos en el mercado con distintos valores de sensibilidad, alcance de la medida, banda de frecuencia de uso, etc., aunque la mayoría suelen ser de dos tipos, los sensores propiamente dichos y los que incorporan un amplificador.

Los sensores piezoeléctricos preamplificados van siendo cada vez más habituales por la comodidad de su uso, ya que producen un valor de tensión proporcional a la excitación aplicada en la salida del amplificador y su comportamiento resulta independiente del conexionado exterior puesto que carga y resistencia de entrada del amplificador se mantienen constante siempre. Este tipo de sensores precisa alimentación.



Los sensores piezoeléctricos propiamente dichos no incorporan más que el dispositivo sensor, careciendo de una salida tan cómoda como los anteriores.

### - ***Acelerómetros piezoresistivos***

Una deformación física del material cambia el valor de las resistencias del puente. Consta de una masa en forma de travesaño y dos medidores de tensión. La masa está introducida en un receptáculo y tiene situados arriba y abajo los dos medidores. Cuando se produce una aceleración en el elemento a medir la pieza en forma de travesaño se dobla y con los medidores de tensión se podrá calcular la aceleración que ha provocado esa torsión. Realmente uno de los medidores se usa para la tensión y otro para la compresión.

### - ***Acelerómetros micromecánicos ( MEMS )***

Este tipo de dispositivos ha sido desarrollado para su empleo como sensor de impacto en los sistemas de airbag, en sistemas antibloqueo de frenos o en cualquier otro proceso en que se pretenda medir impacto.

#### **3.2.1.3 Acelerómetro MMF**

El modelo KS943B.10 de la empresa MMF (figura 3.7) es un acelerómetro triaxial de pequeñas dimensiones adecuado para objetos ligeros con un taladro central que permite fijarlo al elemento sobre el que se colocará dentro del sistema y su correcta alineación de los ejes. Las medidas obtenidas para cada eje se transmiten a través una misma salida, si bien éstas son totalmente independientes, que consiste en un miniconector M5 (figura 3.8) al que se le conecta un cable que permita unir el acelerómetro con otro elemento del sistema de medida como puede ser un amplificador/acondicionador de señal [128].



Figura 3.7: Acelerómetro MMF KS943B.10 [28].

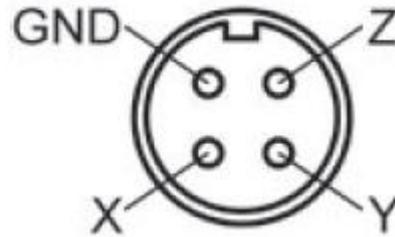


Figura 3.8: Miniconector M5 del acelerómetro MMF KS943B.10 [28].

El elemento activo en el que se basa el funcionamiento del acelerómetro piezoeléctrico empleado es material cerámico cuidadosamente seleccionado con excelentes propiedades piezoeléctricas denominado PZT (titanato de circonio-plomo). Este material especialmente formulado proporciona un rendimiento estable así como estabilidad a largo plazo. La alta sensibilidad, similar a los acelerómetros de cuarzo, se logra mediante el envejecimiento artificial del elemento piezocerámico. La sensibilidad de los cerámicos comparada con materiales de cuarzo es aproximadamente 100 veces mayor, siendo, por tanto, los acelerómetros piezoeléctricos la mejor elección para bajas frecuencias y baja aceleración.

El acelerómetro presenta un diseño constructivo a esfuerzo cortante que presenta la ventaja de tener bajas sensibilidades tanto a los transitorios de temperatura como a las tensiones de la base, aunque, por el contrario, posee una sensibilidad menor a índices de masa en comparación con otros diseños. Este diseño se comprende mejor observando la figura 3.9, en la que se muestra el funcionamiento del acelerómetro empleado:

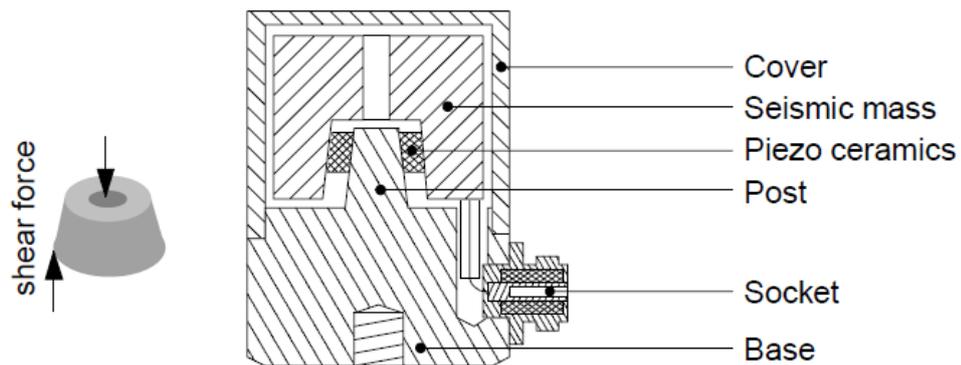


Figura 3.9: Diseño a esfuerzo cortante del acelerómetro MMF KS943B.10 [28].

Las características principales del acelerómetro MMF KS943B.10 se muestran a continuación en la tabla 3.3, así como la respuesta de amplitud típica (eje Z) que presenta este modelo y que se corresponde con la figura 3.10:



Características		KS943B.10
Salida		IEPE
Diseño piezoeléctrico		Diseño a esfuerzo cortante
Sensibilidad de voltaje	$B_{ua}$	$10 \pm 5\%$
Rango	$a_+ / a_-$	600
Límite de destrucción	$a_+ / a_-$	8000
Rango de frecuencia lineal (eje z)	$f_{3\text{ dB}}$	0.2 .. 22000
	$f_{10\%}$	0.4 .. 17000
	$f_{5\%}$	0.6 .. 15000
Frecuencia de resonancia (eje z)	$f_r$	> 42 (25 dB)
Sensibilidad transversal	$\Gamma_{90\text{MAX}}$	< 5
Ruido residual (RMS, 3 Hz-50 kHz)	$a_{n\text{ wide band}}$	<3000
Densidades de ruido	0.1 Hz $a_{n1}$	300
	1 Hz $a_{n2}$	100
	10 Hz $a_{n3}$	30
	100 Hz	10
Fuente de corriente continua	$I_{\text{const}}$	2 .. 20
Voltaje de salida	$U_{\text{BIAS}}$	12 .. 14
Impedancia de salida	$r_{\text{out}}$	< 150
<b>Características ambientales</b>		
Rango de temperaturas de operación	$T_{\text{min}}/T_{\text{max}}$	-20 / 120
Coeficiente de temperatura de sensibilidad	-20 .. 20°C TK( $B_a$ )	0.05
	20 .. 80°C	$\pm 0.02$
	80 .. 120°C	-0.06
Sensibilidad transitoria de temperatura	$b_{aT}$	0.03



Datos mecánicos		
Peso sin cable	m	14 / 0.5
Material de la carcasa	Aluminio	
Toma de corriente	Binder 707	
Conexiones de montaje	M3 (Y), M3 (Z)	

Tabla 3.3: Características del acelerómetro MMF KS943B.10.

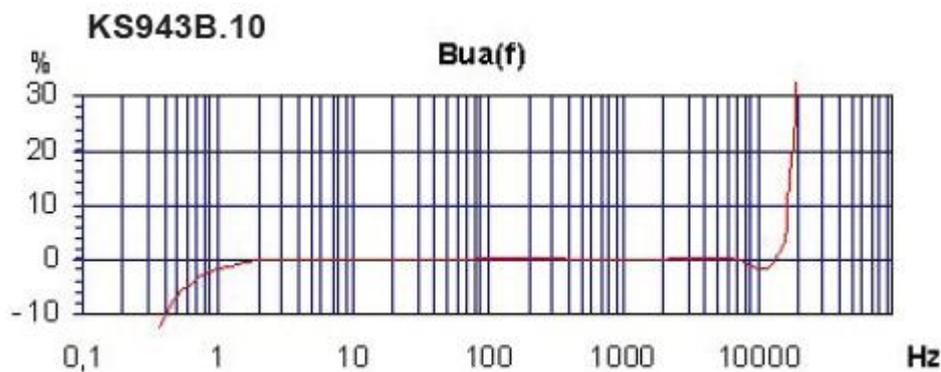


Figura 3.10: Respuesta de amplitud típica (eje Z) [28].

## **3.2.2 FILTROS MMF**

### **3.2.2.1 Introducción**

Con el propósito de poder usar las señales tomadas con el acelerómetro, es necesario conectar éste último a unos filtros acondicionadores de señal que preparan la señal para su posterior captura mediante una tarjeta de adquisición de datos. En este proyecto, se han empleado cuatro módulos acondicionadores MMF M32 (figura 3.11), los cuáles son unos acondicionadores de señal para transductores con salida compatible IEPE. Estos módulos proporcionan la fuente de alimentación necesaria para el circuito electrónico del sensor. La unidad ofrece tres rangos de ganancia y un filtro paso bajo conectable. El M32 puede usarse como interfaz para PC's basados en sistemas de adquisición de datos. Este módulo es adecuado para ambas aplicaciones en bancos de ensayos y acoplamiento de raíles DIN en armarios de conmutadores. El amplio rango voltaje del M32 permite el suministro de energía de baterías externas, desde los adaptadores principales disponibles o desde una fuente industrial de 24 VDC [29].



Figura 3.11: Módulo MMF M32 [29].

IEPE es un estándar sólidamente establecido para la salida de transductores y micrófonos piezoeléctricos. Su nombre viene de “Integrated Electronics Piezo Electric”. Otras marcas para el mismo principio son ICP<sup>®</sup>, Isotron<sup>®</sup>, Deltatron<sup>®</sup>, Piezotron<sup>®</sup>, etc. El circuito integrado del sensor transforma la señal de carga del elemento sensor piezocerámico, con su muy alta impedancia y su alta sensibilidad EMI, en una señal de voltaje con baja impedancia.

Una característica especial de la electrónica IEPE es que esa fuente de alimentación y la señal medida se transmiten a través del mismo cable. Así que, un transductor requiere, como un transductor con salida de carga, sólo un cable apantallado de terminación simple.

Los sensores electrónicos integrados están alimentados con corriente continua. Esto no debe confundirse con un bucle de corriente de 4-20 mA. La corriente continua  $I_{const}$  se proporciona con el cable de señal del sensor. Un condensador de desacoplo mantiene alejados los componentes DC del circuito acondicionador de señal. La fuente de corriente constante y el condensador de desacoplo son parte del M32 (véase la figura 3.12).

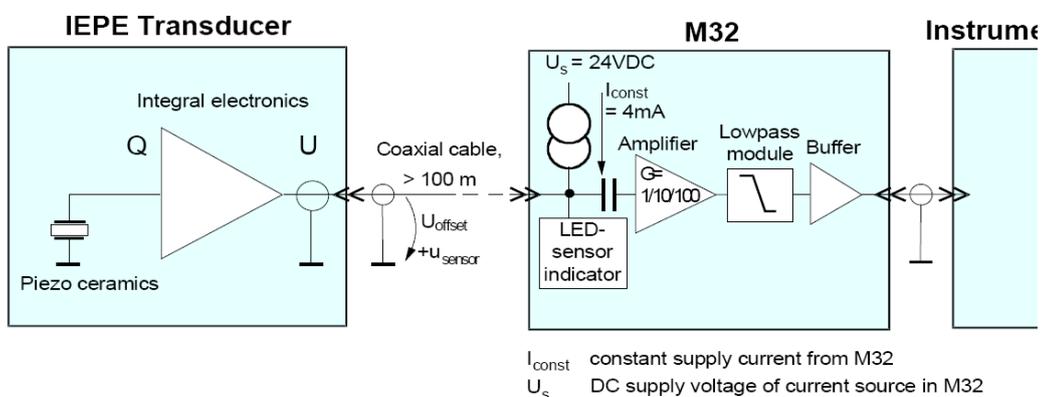


Figura 3.12: Diagrama funcional y principio IEPE del M32 [29].



Debido a la alimentación del sensor con corriente constante surge un voltaje de offset DC positivo. Este voltaje DC depende del fabricante y del modelo y va de 5V a 14V. La señal medida del transductor puede oscilar alrededor de este voltaje. El voltaje de salida del transductor nunca cambia a valores negativos. Su valor mínimo es el voltaje de saturación de la electrónica integrada (alrededor de 1V). El valor máximo del voltaje de salida está limitado por el voltaje de alimentación de la fuente de corriente constante (24 VDC con el M32). La figura 6.13 muestra el rango dinámico del transductor. La salida del M32 está libre de componentes DC. Esto proporciona la señal de salida del sensor AC inalterada.

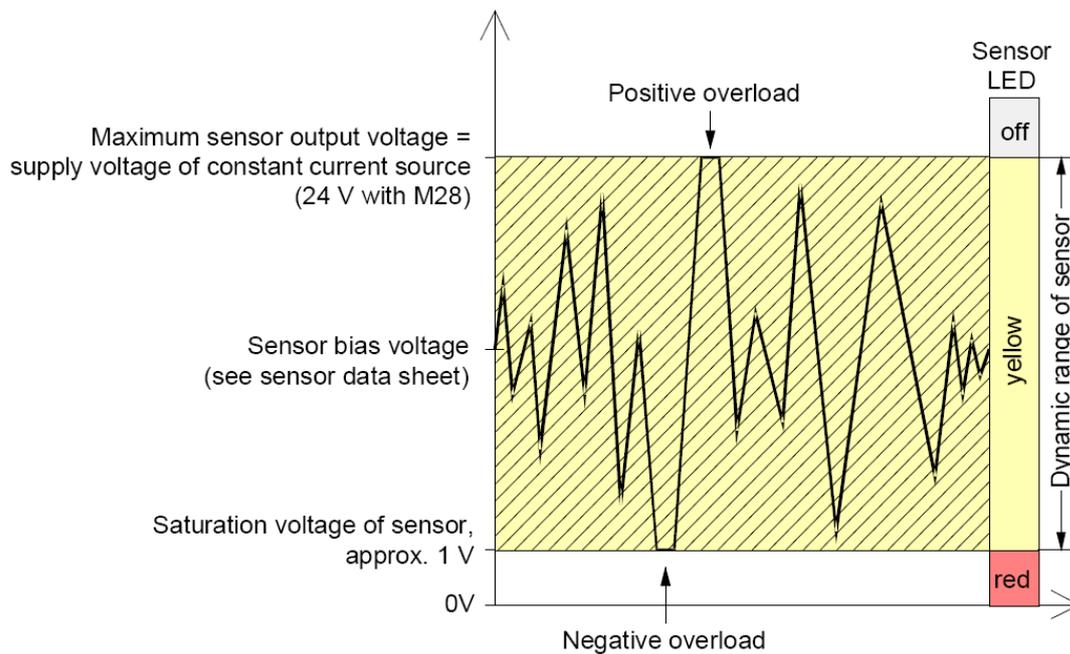


Figura 3.13: Rango dinámico de los sensores IEPE [29].

### 3.2.2.2 Características

Los módulos acondicionadores IEPE M32 contienen el circuito electrónico para el suministro de un sensor. Para aplicaciones multicanal estos módulos se pueden conectar entre sí mediante banana plugs enroscadas en un lateral del módulo. Estas conexiones conectan la fuente de alimentación a todos los módulos.

Los módulos M32 requieren para su funcionamiento un suministro de entre 5 y 26 VDC. Éste puede suministrarse, por ejemplo, mediante:

- Fuentes industriales de 24VDC.
- Los adaptadores disponibles opcionalmente PS500 (para un M32) y PS1000 (para hasta 3 unidades M32).
- Baterías de más de 5 VDC.
- Voltaje PC o USB (5 o 12 VDC).



La fuente de alimentación se conecta a través de un conector circular DIN 45323 en el lateral izquierdo del módulo. Alternativamente, los dos banana plugs del lado izquierdo de la carcasa se pueden usar como fuente de alimentación. Un LED de color verde indica la conexión de la fuente de alimentación.

El M32 está protegido contra falsa polarización y transitorios de línea de hasta 60 V. También se proporciona aislamiento entre la fuente de alimentación y la señal medida.

Además, se genera internamente un voltaje de alimentación de 24 VDC para la fuente de corriente constante. Este voltaje es suficiente para un rango dinámico óptimo con todos los transductores compatibles IEPE disponibles.

Un LED indicador de estado informa al usuario de las siguientes condiciones:

- LED apagado: no hay sensor conectado o el circuito del sensor se ha interrumpido.
- LED amarillo: el sensor está conectado adecuadamente con un voltaje de alimentación entre 1 y 24 VDC.
- LED rojo: entrada cortada, voltaje entre 1 VDC.

La ganancia del M32 se puede seleccionar mediante un interruptor giratorio entre 1, 10 y 100. Además, es adecuado para medidas con transductores piezoeléctricos desde 0.1 Hz hasta 30kHz. Así, se pueden realizar medidas sísmicas a bajas frecuencias con acelerómetros o medidas de presión y fuerza cuasiestáticas. También es posible tomar medidas de impacto involucrando altas frecuencias y amplitudes.

El M32 tiene un filtro paso bajo tipo FB2-... con características Butterworth de 4º orden. Metra ofrece una variedad de filtros con frecuencias de corte entre 100 Hz y 30 kHz. Desatornillando el panel trasero y deslizándolo se accede al filtro.

En la tabla 3.4 se muestran las principales características de los módulos acondicionadores de señal MMF M32:



Datos técnicos	
Entrada / salida	Enchufes BNC
Circuito de salida	DC acoplada; impedancia aproximada 100 $\Omega$
Rango dinámico	$\pm 10$ V
Fuente de corriente continua	3.8 .. 5.6 mA, voltaje >24 V
Indicador de sensor IEPE	LED bicolor; off = entrada abierta; amarillo = 1 .. 24 V = OK; rojo = cortado
Rangos de ganancia	1 / 10 / 100 $\pm 1$ % típicamente, $\pm 2$ % máximo
Ruido de salida	< 1 mV <sub>rms</sub> con paso bajo a 30 kHz
Rango de frecuencias (-3 dB)	0.1 Hz .. 30 kHz (dependiendo del módulo paso bajo)
Filtro paso bajo	Módulo enchufable FB2-...; Butterworth; 4º orden; atenuación > 70 dB/década; frecuencias disponibles (-3 dB): FB2 – 0.1 / 0,3 / 1 / 3 / 5 / 10 / 30 kHz
Fuente de alimentación	U <sub>s</sub> =5 .. 26 VDC; <200 mA; aislada de la señal; conector DIN 45323 o banana plugs
Carcasa	Aluminio, conectada al terminal negativo de la fuente de alimentación
Temperatura de operación	-10 – 55 °C; 95 % de humedad relativa; sin condensación
Peso	170 g
Dimensiones (ancho x alto x fondo)	56 mm x 59 mm x 44 mm

Tabla 3.4: Características de los acondicionadores de señal MMF M32.

### **3.2.3 TARJETA DE ADQUISICIÓN DE DATOS KEITHLEY**

#### **3.2.3.1 Introducción**

Para la adquisición de datos se emplea una tarjeta serie KUSB-3100 del fabricante Keithley, la cual trae una verdadera conexión plug-and-play de adquisición de datos para ordenadores que tengan puertos USB 2.0 o 1.1. Con este tipo de tarjetas de adquisición de datos no es necesario abrir el ordenador para instalarlas, sólo es preciso conectar el módulo e instalar el software proporcionado.



La ventaja de la conexión USB es que todos los ordenadores poseen un puerto USB. Además, este tipo de puertos se pueden instalar fácilmente en máquinas PCI-bus. Igualmente importante, estos puertos USB tienen un total soporte de software bajo los sistemas operativos más populares, incluyendo Windows 2000, XP y Vista [30].

La conexión plug-and-play permite que el PC detecte automáticamente el módulo de adquisición de datos KUSB-3100 cuando es conectado al ordenador y busque el software necesario para su funcionamiento. La primera vez que se usa un módulo de este tipo, se le solicita al usuario instalar los controladores y aplicaciones, algo que sólo lleva unos pocos minutos. Esta facilidad de instalación significa la intercambiabilidad entre diferentes ordenadores, tales como ordenadores portátiles y de sobremesa.

Las tarjetas de la serie KUSB-3100 son externas al ordenador. Esta localización externa proporciona beneficios en el rendimiento para dispositivos sensibles al ruido tales como sistemas de adquisición. Estas tarjetas se pueden colocar lejos de las fuentes de ruido como Pc's y fuentes de alimentación y se pueden colocar cerca de las señales que se quieren medir.

Debido a que dichas tarjetas se colocan fuera del ordenador, pueden ser susceptibles de picos de baja, ESD, sobrecargas y otras condiciones dañinas. Estos picos pueden causar fallos en el sistema y pueden causar incluso daños permanentes al ordenador.

Las características principales de la tarjeta de adquisición de datos se muestran en la tabla 3.5:

<b>Descripción</b>	Bajo coste, multifunción
<b>Resolución</b>	12 bit
<b>Tasa de transferencia</b>	50 kS/s
<b>Canales de entrada analógica</b>	8 SE
<b>Canales de salida analógica</b>	2
<b>Canales digitales I/O</b>	16
<b>Contador/Reloj</b>	1
<b>Ganancia</b>	1, 2, 4, 8

Tabla 3.5: Características básicas de la tarjeta de adquisición de datos Keithley KUSB-3100.



### 3.2.3.2 Entradas analógicas

Todas las tarjetas KUSB-3100 (excepto KUSB-3160) ofrecen hasta 16 entradas en modo común u ocho entradas diferenciales. Los ajustes de ganancia seleccionables por software en los KUSB-3100, -3102A y -3116 son 1, 2, 4, y 8, cuyas gamas de entrada proporcionadas son de  $\pm 1.25V$ ,  $\pm 2.5$ ,  $\pm 5$  y  $\pm 10$ .

- Modos de adquisición de entradas analógicas

Las entradas analógicas permiten adquirir un valor único de un canal o un número de muestras de canales múltiples. Para adquirir datos de canales múltiples, se proporcionan dos modos de escaneo: de paso continuo y disparo. Con el modo de paso continuo, el módulo escanea continuamente la lista de canales de ganancia y adquiere datos hasta que el usuario pare la operación o hasta que se adquiera un número específico de muestras. Con el modo de disparo el módulo escanea la lista de canales a alta velocidad con un intervalo programado entre escaneo, emulando una operación simultánea de muestreo y retención.

Para una flexibilidad mayor, una lista de canales multiposición permite muestrear canales no secuenciales y canales con diferentes ganancias. La resolución A/D y el rango de muestreo máximo varían dependiendo del tipo de módulo empleado.

- Salidas analógicas

El módulo KUSB-3100 ofrece dos salidas analógicas de  $\pm 10V$  de 12 bits de resolución con una tasa de transferencia de 50 kHz.

- I/O digital

El módulo KUSB-3100 proporciona un amplio rango de líneas digitales I/O. Estas líneas están divididas en conjuntos de puertos de entrada y salida.

- Contador/Reloj

En el módulo KUSB-3100 hay disponibles contadores/relojes dedicados para eventos de cálculo, creando una salida única o de frecuencia. Si es aplicable, se pueden poner dos contadores internos en cascada mediante software o más de dos contadores externos en cascada.

- Conexiones

Un simple cable USB proporciona tanto la energía como las conexiones de señal desde el PC, por lo que no es necesaria ninguna fuente de alimentación externa o batería.

Las conexiones de señal están hechas directamente para cada módulo usando cualquiera de los terminales con tornillo, conectores BNC o conectores D-type de 37-pines situados en el mismo módulo.



# **Capítulo 4:**

## Software

## 4. SOFTWARE

En este cuarto capítulo se pretende dar una breve descripción acerca de los programas informáticos empleados para el desarrollo de este proyecto. Los programas empleados son TestPoint™ y MATLAB®, que permiten la adquisición de datos y el posterior tratamiento de los mismos respectivamente.

### 4.1 TESTPOINT™

El programa TestPoint™, desarrollado por CEC (Capital Equipment Corporation), es una herramienta para la creación de test ‘personalizados’, aplicaciones de adquisición de datos y la realización de medidas. En la figura 4.1 se muestra un ejemplo de la pantalla principal del TestPoint™.

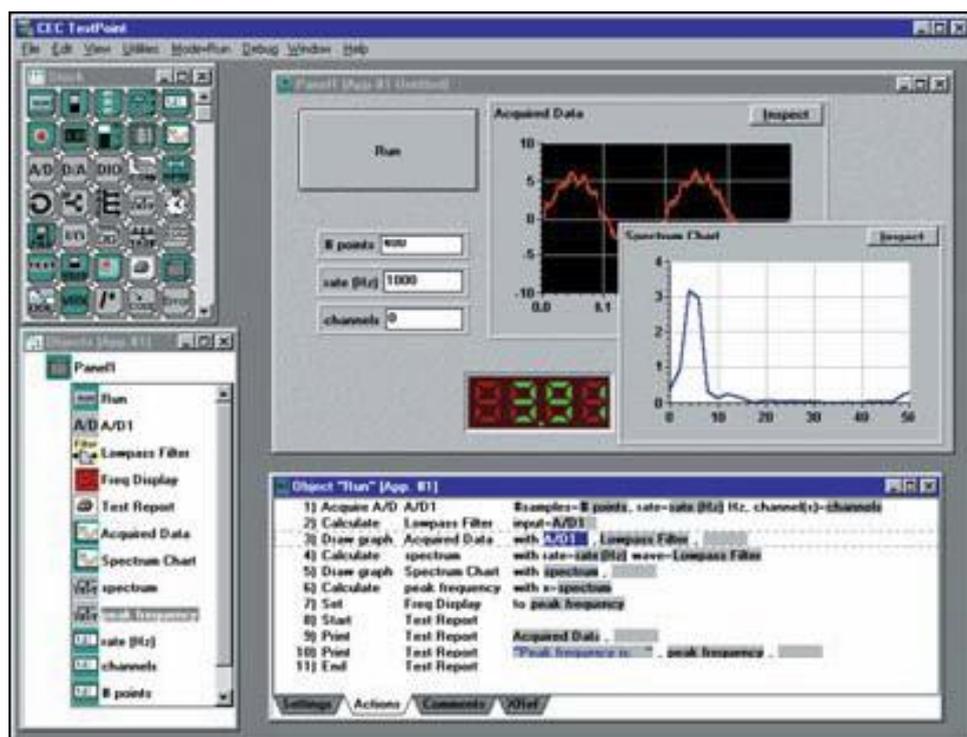


Figura 4.1: Pantalla del programa TestPoint™.

TestPoint™ posee unas características que le permiten controlar hardware externo, crear interfaces de usuario, procesar y visualizar datos, crear ficheros e intercambiar información con otros programas de Windows [31].

Dicho programa es una nueva y única alternativa a los lenguajes de programación convencionales. En el TestPoint™, el usuario puede seleccionar objetos que formen los componentes de su aplicación, para, posteriormente, combinar las acciones que hagan posible el uso de las operaciones del ratón de arrastrar y soltar para crear una solución adaptada a las necesidades del usuario.

TestPoint™ tiene toda la potencia y la flexibilidad de un lenguaje de programación. No hay ninguna de las limitaciones asociadas a los programas en los que es necesario seleccionar



objetos desde un menú, debido a que el TestPoint™ tiene un completo conjunto de características para controlar el flujo de programa, acceder al hardware personalizado y extender el programa de aplicación básico con código externo, complementos y enlaces de intercambio de datos con otros programas.

A continuación se presentan las diferentes funciones que puede desarrollar el programa TestPoint™:

#### Control de instrumentos

- Biblioteca de instrumentos para cientos de dispositivos populares.
- Soporte para dispositivos GPIB (IEEE-488), RS-232 y RS485.
- Soporte para dispositivos VXI a través de un controlador GPIB.

#### Adquisición de datos

- Soporte para entrada y salida analógica (A/D, D/A), digital I/O y dispositivos de puerto I/O personalizados.
- Alta velocidad A/D.
- Gráficos de bandas, indicadores de barra y displays numéricos.
- Límites de alarma.
- Registro de disco.

#### Análisis

- FFT (Fast Fourier Transform), filtro digital, suavizado de la forma de onda.
- Adaptación de curvas, polinomios, interpolación.
- Estadística, incluyendo media, desviación, mediana, histogramas,...
- Vectores y matrices, incluyendo inversa, determinante,...

#### Presentación e informes

- Gráficas de líneas/símbolos, gráficos X/Y, gráficos de bandas, gráficos de barras.
- Displays de barras numéricos y analógicos.
- Indicadores e imágenes de mapas de bits.
- Generación impresa del informe.



### Interfaz de usuario

- Botones de contacto, interruptores, selectores, barras de desplazamiento, campos de entrada.
- Paneles múltiples.
- Trabaja con controles personalizados estándar de la industria (VBXs).

### Intercambio dinámico de datos / Enlace y encaje de objetos

- Enviar/recibir números, texto y gráficos para hojas de cálculo, procesadores de texto, bases de datos y programas matemáticos.
- Visualización de gráficos e imágenes procesados por otras aplicaciones.

## **4.2 MATLAB®**

### **4.2.1 INTRODUCCIÓN**

MATLAB® es un lenguaje de computación técnica de alto nivel y un entorno interactivo para desarrollo de algoritmos, visualización de datos, análisis de datos y cálculo numérico. Con MATLAB®, se pueden resolver problemas de cálculo técnico más rápidamente que con lenguajes de programación tradicionales, tales como C, C++ y FORTRAN porque no es necesario realizar tareas administrativas de bajo nivel, tales como declarar variables, especificar tipos de datos y asignar memoria [32].

MATLAB® puede usarse en una amplia gama de aplicaciones que incluyen procesamiento de señales e imágenes, comunicaciones, diseño de sistemas de control, sistemas de prueba y medición, modelado y análisis financiero y biología computacional. Los conjuntos de herramientas complementarios amplían el entorno de MATLAB® permitiendo resolver problemas especiales en estas áreas de aplicación.

Además, MATLAB® contiene una serie de funciones para documentar y compartir el trabajo. Puede integrarse el código de MATLAB® con otros lenguajes y aplicaciones, y distribuir los algoritmos y aplicaciones que se desarrollen usando MATLAB®. Las principales características que ofrece este programa son:

- Entorno de desarrollo para la gestión de código, archivos y datos.
- Herramientas interactivas para exploración, diseño y resolución de problemas iterativos.
- Funciones matemáticas para álgebra lineal, estadística, análisis de Fourier, filtraje, optimización e integración numérica.
- Funciones gráficas bidimensionales y tridimensionales para visualización de datos.



- Herramientas para crear interfaces gráficas de usuario personalizadas.
- Funciones para integrar los algoritmos basados en MATLAB® con aplicaciones y lenguajes externos, tales como C/C++, FORTRAN, Java, COM y Microsoft Excel.

El lenguaje MATLAB® incluye operaciones vectoriales y matriciales que son fundamentales para resolver los problemas científicos y de ingeniería. Agiliza tanto el desarrollo como la ejecución.

Para ejecutar rápidamente cálculos matriciales y vectoriales complejos, MATLAB® utiliza bibliotecas optimizadas para el procesador.

- Diseño de interfaces gráficas de usuario

La herramienta interactiva GUIDE (Graphical User Interface Development Environment) puede usarse para diseñar y editar interfaces de usuario. Esta herramienta permite incluir listas de selección, menús desplegables, botones de pulsación, botones de opción y deslizadores, así como diagramas de MATLAB® y controles ActiveX.

- Análisis y acceso a datos

MATLAB® soporta todo el proceso de análisis de datos, desde la adquisición de datos de dispositivos externos y bases de datos, pasando por el preprocesado, visualización y análisis numérico, hasta la producción de resultados con calidad de presentación.

MATLAB® proporciona herramientas interactivas y funciones de línea de comandos para operaciones de análisis de datos, entre las que se incluyen:

- Interpolación y diezmado.
- Extracción de secciones de datos, escalado y promediación.
- Umbralización y suavizamiento.
- Correlación, análisis de Fourier y filtraje.
- Búsqueda de picos unidimensionales, valles y ceros.
- Estadística básica y ajuste de curvas.
- Análisis matricial.

MATLAB® es una plataforma eficiente para acceder a datos de archivos, otras aplicaciones, bases de datos y dispositivos externos. Se pueden leer datos guardados en los formatos más conocidos, tales como Microsoft Excel, archivos de texto ASCII o binarios, archivos de imagen, sonido y vídeo, y archivos científicos como HDF y HDF5. Las funciones de E/S de archivos binarios de bajo nivel permiten trabajar con archivos de datos en cualquier formato.



- Visualización de datos

Todas las funciones gráficas necesarias para visualizar datos de ingeniería y científicos están disponibles en MATLAB®. Incluye funciones de representación de diagramas bidimensionales y tridimensionales, visualización de volumen tridimensional, herramientas para crear diagramas en forma interactiva y la posibilidad de exportar los resultados a los formatos gráficos más conocidos.

- Cálculo numérico

MATLAB® contiene funciones matemáticas, estadísticas e ingenieriles para soportar todas las operaciones ingenieriles y científicas típicas. Las funciones matemáticas centrales emplean las bibliotecas de subrutinas de álgebra lineal LAPACK y BLAS y la biblioteca de la transformada discreta de Fourier (FFTW).

MATLAB® proporciona los siguientes tipos de funciones para realizar operaciones matemáticas y análisis de datos:

- Manipulación de matrices y álgebra lineal.
- Polinomios e interpolación.
- Análisis de Fourier y filtrado.
- Análisis de datos y estadística.
- Optimización e integración numérica.
- Ecuaciones diferenciales ordinarias (ODEs).
- Ecuaciones diferenciales parciales (PDEs).
- Operaciones de matrices dispersas.

## **4.2.2 NEURAL NETWORK TOOLBOX DE MATLAB®**

### **4.2.2.1 Introducción**

Neural Network Toolbox™ amplía MATLAB® con herramientas para diseñar, implementar, visualizar y simular redes neuronales. Las redes neuronales no son evaluables para aplicaciones donde análisis formales serían difíciles o imposibles, tales como reconocimiento de patrones y sistemas de identificación y control no lineales. Neural Network Toolbox™ proporciona un soporte completo para muchos tipos de redes probados, así como interfaces gráficas de usuario (GUIs) que permiten diseñar y gestionar las redes. El diseño modular y ampliable del toolbox simplifica la creación de funciones y redes personalizadas. Las principales características que ofrece esta herramienta de MATLAB® son las siguientes [32]:



- GUI para crear, entrenar y simular redes neuronales.
- Asistentes de inicio rápido para ajustar, reconocimiento de patrones y agrupar.
- Soporte para la mayoría de las arquitecturas de redes supervisadas y no supervisadas empleadas comúnmente.
- Conjunto detallado de funciones de entrenamiento y aprendizaje.
- Redes de aprendizaje dinámico, incluyendo retardo de tiempo, autoregresión no lineal (NARX), capa recurrente y dinámica personalizada.
- Bloques Simulink® para la construcción de redes neuronales y bloques avanzados para aplicaciones de sistemas de control.
- Soporte para la generación automática de bloques Simulink® desde objetos de redes neuronales.
- Representación de red modular que permite un número ilimitado de capas de entrada-salida e interconexiones de redes y una vista gráfica de la arquitectura de red.
- Funciones de preprocesado y postprocesado y bloques Simulink® para mejorar el entrenamiento de la red y evaluar el rendimiento de la red.
- Funciones de visualización y GUI para ver el rendimiento de la red y monitorizar el proceso de entrenamiento.

Como su homóloga en el sistema nervioso biológico, una red neuronal puede aprender y por lo tanto ser entrenada para encontrar soluciones, reconocer patrones, clasificar datos y predecir acontecimientos futuros. El comportamiento de una red neuronal se define por el modo en que sus elementos computacionales individuales están conectados y por la intensidad de estas conexiones o pesos. Los pesos están ajustados automáticamente por el entrenamiento de la red según una norma de aprendizaje especificada hasta que realice la tarea deseada correctamente. Las redes neurales se desarrollarán con más detalle en el capítulo 6.

Neural Network Toolbox GUIs hace fácil el trabajo con redes neurales. La Neural Network Fitting Tool es un asistente que dirige al usuario a través del proceso de ajuste de los datos usando redes neuronales. Además, se pueden importar grandes y complejos conjuntos de datos mediante esta herramienta, así como crear y entrenar rápidamente redes neuronales y evaluar el rendimiento de la red.

Una segunda GUI proporciona una mayor habilidad para adaptar la arquitectura de la red y los algoritmos de aprendizaje. Las representaciones gráficas sencillas permiten visualizar y comprender la arquitectura de la red.

También hay disponibles GUIs adicionales para otras tareas comunes incluyendo reconocimiento de patrones, agrupar datos y entrenar redes.



#### **4.2.2.2 Arquitecturas de redes**

La herramienta Neural Network Toolbox de MATLAB® soporta tanto redes supervisadas como no supervisadas.

- **Redes supervisadas**

Las redes neuronales supervisadas se entrenan para producir las salidas deseadas en respuesta a unas entradas de muestra, haciéndolas particularmente adecuadas al modelado y control de sistemas dinámicos, clasificación de datos de ruido y predicción de acontecimientos futuros. Neural Network Toolbox soporta cuatro redes supervisadas: feedforward, de base radial, dinámica y LVQ.

- Las redes feedforward tienen conexiones desde las capas de entrada hasta las de salida. Estas redes se emplean generalmente para predicción, reconocimiento de patrones y ajuste de funciones no lineales. Las redes feedforward soportadas incluyen retropropagación feedforward, retropropagación hacia delante en cascada, retropropagación de retraso de entrada feedforward, lineal y perceptron.
- Las redes de base radial proporcionan una alternativa, un método rápido para diseñar redes feedforward no lineales. Las variaciones soportadas incluyen regresión generalizada y redes neuronales probabilísticas.
- Las redes dinámicas usan memoria y conexiones de realimentación recurrente para reconocer patrones espaciales y temporales en datos. Se usan comúnmente para predicción de series temporales, modelado de sistemas dinámicos no lineales y aplicaciones de sistemas de control. Las redes dinámicas predefinidas en la toolbox incluyen redes de retardo de tiempo centrado y distribuido, autoregresión no lineal (NARX), capa recurrente, Elman y Hopfield. La toolbox soporta además entrenamiento dinámico de redes personalizadas con conexiones arbitrarias.
- LVQ es un potente método para clasificar patrones que no son linealmente separables. LCQ permite especificar fronteras de clases y la particularidad de la clasificación.

- **Redes no supervisadas**

Las redes neuronales no supervisadas se entrenan permitiendo a la red ajustarse continuamente a sí misma a las nuevas entradas. Estas redes encuentran relaciones dentro de los datos y pueden definir automáticamente métodos de clasificación.

Neural Network Toolbox soporta dos tipos de auto organización, redes no supervisadas: capas competitivas y mapas auto organizados.

Las capas competitivas reconocen y agrupan vectores de entrada similares. Mediante estos grupos, la red ordena automáticamente las entradas en categorías.

Los mapas auto organizados aprenden a clasificar vectores de entrada según su similitud. Al contrario que las capas competitivas, conservan además la topología de los vectores de entrada, asignando entradas cercanas a categorías cercanas.



#### **4.2.2.3 Funciones de entrenamiento y aprendizaje**

Las funciones de entrenamiento y aprendizaje son procedimientos matemáticos empleados automáticamente para ajustar los pesos y desviaciones de la red. La función de entrenamiento establece un algoritmo global que afecta a todos los pesos y desviaciones de una red dada. La función de aprendizaje se puede aplicar a pesos y desviaciones individuales dentro de una red.

Neural Network Toolbox soporta muchos algoritmos de entrenamiento, incluyendo varios métodos de pendiente descendente, métodos de pendiente conjugada, el algoritmo de Levenberg-Marquardt (LM) y el algoritmo de retropropagación elástica (Rprop). Los algoritmos son accesibles desde la línea de comandos o mediante una GUI de entrenamiento, que muestra un diagrama de la red siendo entrenada, alternativas de algoritmos de entrenamiento y valores de criterio de parada como los progresos de entrenamiento.

También se proporciona un conjunto de funciones de aprendizaje, incluyendo gradiente descendente, aprendizaje hebbiano, LVQ, Widrow-Hoff y Kohonen.

#### **4.2.2.4 Soporte Simulink y aplicaciones de sistemas de control**

Neural Network Toolbox proporciona un conjunto de bloques para construir redes neuronales en Simulink. Estos bloques están divididos en tres bibliotecas:

- Bloques de funciones de transferencia, que toman un vector de entrada y generan el correspondiente vector de salida.
- Bloques de funciones de entrada de red, que toman cualquier número de vectores de entrada ponderados, vectores de salida de capas ponderadas y vectores de desviación y devuelven un vector de entrada de red.
- Bloques de funciones de pesos, que aplican un vector de pesos de una neurona a un vector de entrada (o a un vector de salida de una capa) para obtener un valor de entrada ponderado para una neurona.
- Bloque de preprocesado de datos, que trazan los datos de entrada y salida en los rangos más adecuados para la red neuronal para manejarlos directamente.
- Alternativamente, se pueden crear y entrenar redes propias en el entorno MATLAB® y generar automáticamente bloques de simulación de red para usar con Simulink®. Esta propuesta también permite ver dichas redes gráficamente (figura 4.2).

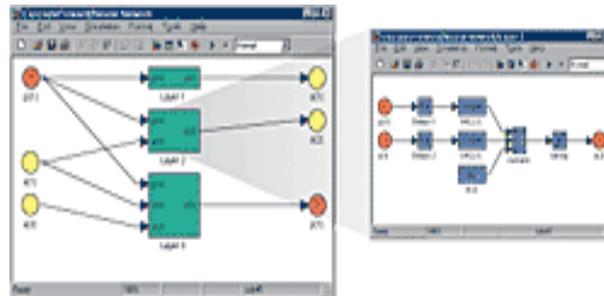


Figura 4.2: Red neuronal de tres capas convertida en bloques Simulink® [32].

Neural Network Toolbox también permite aplicar redes neuronales para la identificación y control de sistemas no lineales. La toolbox incluye descripciones, demostraciones y bloques Simulink para tres populares aplicaciones de control: control de modelo predictivo, linealización realimentada y control de modelo de referencia adaptativo.

También se pueden incorporar bloques de control predictivos de redes neuronales incluidos en la toolbox en modelos Simulink. Cambiando los parámetros de estos bloques, se puede adaptar el rendimiento de la red a la aplicación deseada.

#### **4.2.2.5 Funciones de preprocesado y postprocesado**

Preprocesar las entradas de la red y los objetivos mejora la eficiencia del entrenamiento de la red neuronal. El postprocesado permite un análisis detallado del rendimiento de la red. Neural Network Toolbox proporciona funciones de preprocesado y postprocesado y bloques Simulink que permiten:

- Reducir las dimensiones de los vectores de entrada usando el análisis de componentes principales.
- Realizar análisis de regresión entre la respuesta de la red y los correspondientes objetivos.
- Escalar entradas y objetivos para que caigan en el rango  $[-1, 1]$ .
- Normalizar la media y la desviación estándar del conjunto de entrenamiento.
- El preprocesado automático de datos y división de datos se realizan en el proceso de creación de la red.



# **Capítulo 5:**

---

---

## Desarrollo del proyecto



**5. DESARROLLO DEL PROYECTO**

En este capítulo se procederá a describir las características de los ensayos realizados y comentar todos los parámetros considerados para el correcto desarrollo de los estudios efectuados. También se detallarán los programas empleados en el tratamiento de las señales adquiridas y los valores de las redes utilizadas.

**5.1 DESCRIPCIÓN DE LOS ENSAYOS**

Los ensayos realizados consisten en una prueba de arranque tal y como tendría lugar en cualquier situación real y que es un caso crítico ante la presencia de una fisura en un eje. Esta prueba consiste en generar una rampa, previamente programada en el controlador del banco de ensayos, con una duración de 10 segundos, de los cuáles los ocho primeros corresponde a la etapa de aceleración, hasta llegar a 80 Hz (4800 rpm), y los dos siguientes a la etapa de velocidad constante, tal y como se puede apreciar en la figura 5.1, donde se muestra un gráfico de este ensayo.

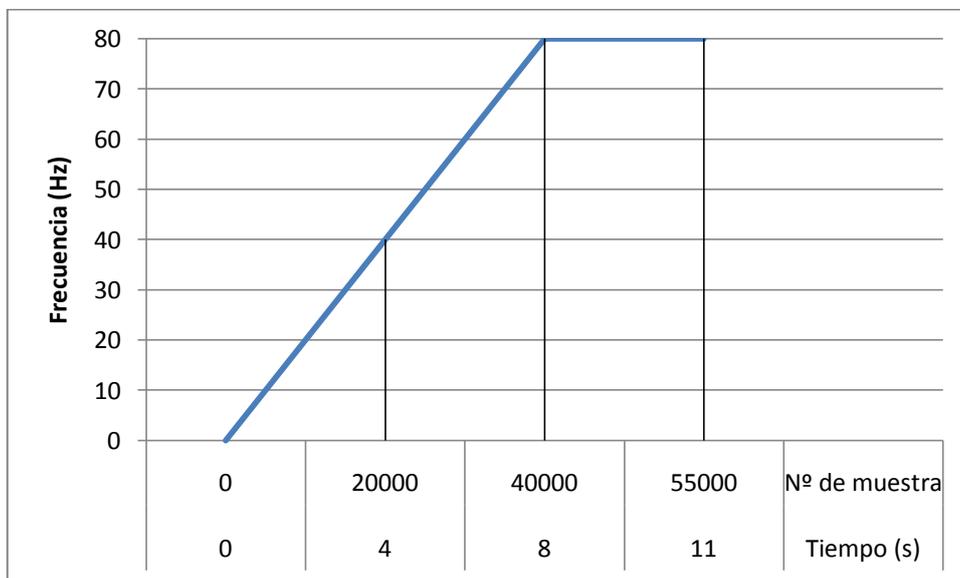


Figura 5.1: Rampa de ensayo realizada.

Hay que decir que, aunque la rampa programada en el Rotokit tiene una duración de 10 segundos, en el programa TestPoint se han medido 11 segundos para poder asegurar el ensayo completo, ya que es necesario este margen para salvar el desfase existente y necesario entre el inicio de la toma de medidas por parte de este programa y el inicio de la ejecución del ensayo por parte del banco de ensayos, puesto que ambos hay que iniciarlos de forma manual y no se ha realizado la automatización del mismo en este proceso. Para ello, se han tomado 5000 muestras por segundo, llegándose a tener un total de 55000 muestras durante el ensayo. Además, hay que añadir el hecho de que antes de tomar cualquier medida válida, se ha procedido previamente a mantener, durante un cierto tiempo, la máquina funcionando a una

velocidad aproximada de 20 Hz (1200rpm) con el fin de que todos los elementos del Rotokit se encuentren en condiciones óptimas de funcionamiento.

En cuanto a la toma de datos se han tomado 18 medidas de cada tipo de ensayo y las medidas obtenidas se han dividido en tres zonas, como muestra la figura 5.1. La primera de ellas, corresponde a una zona inicial, denominada zona A y concierne al tramo 0 – 20000 o, lo que es lo mismo, de 0 a 4 segundos; luego se tiene otra zona intermedia, zona B, perteneciente al intervalo 20000-40000 (4-8 segundos) y una última (zona C) correspondiente a 40000 y 55000 (8-11 segundos) y referida a la zona de velocidad constante. Esta división se ha hecho para poder realizar un estudio más detallado sobre las señales generadas durante el funcionamiento del eje y poder averiguar qué zona es la más recomendable para su uso en las redes neuronales y su posterior clasificación por estas últimas. La velocidad del eje se ha utilizado como una comprobación del ensayo que permite conocer si el sistema de medida toma los datos correctamente.

Además, hay que considerar que los filtros empleados se han fijado con una ganancia unidad para la velocidad y de diez para las medidas de aceleración correspondientes a los ejes X, Y y Z. La orientación de estos tres ejes X, Y y Z según el sistema cartesiano viene definida por la colocación del acelerómetro en el banco de ensayos. La disposición del acelerómetro y el sistema de coordenadas puede verse en la figura 5.2 desde una vista frontal<sup>3</sup>:

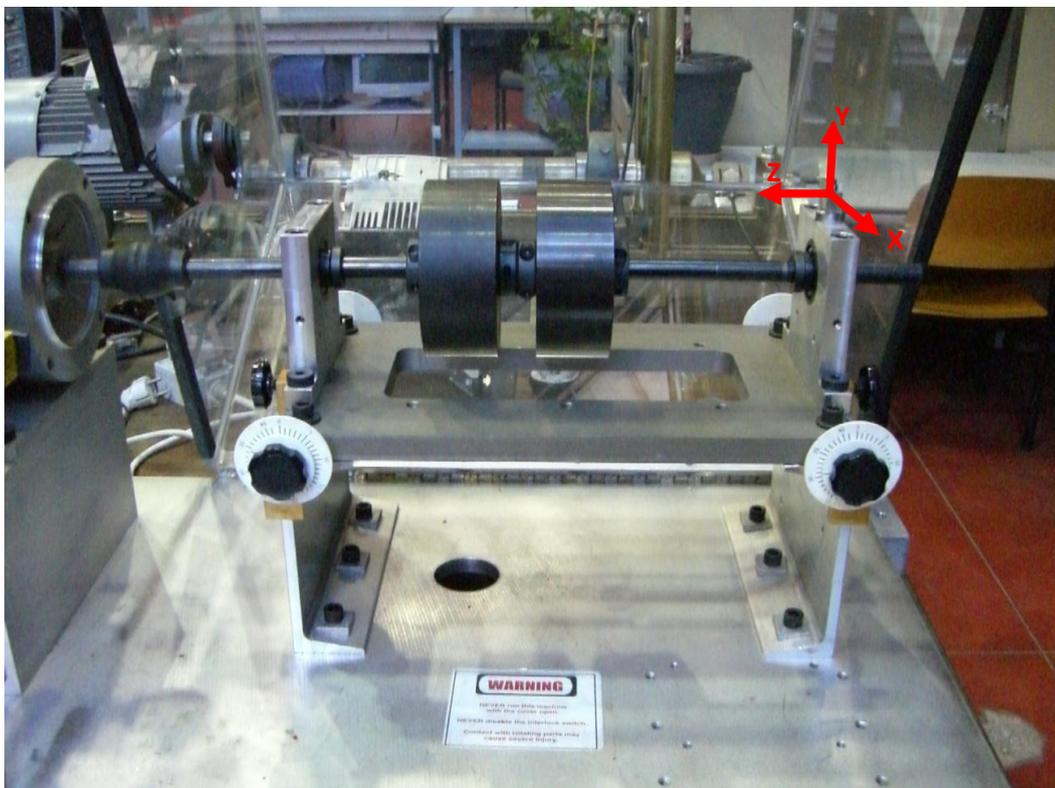


Figura 5.2: Orientación de los ejes en el sistema.

<sup>3</sup> La configuración del eje y los discos mostrada en esta imagen no se corresponde con la empleada en los ensayos, si bien la colocación del acelerómetro es la misma.



Los ensayos llevados a cabo consisten en colocar sobre un eje dos discos, como los que muestra la figura 5.3, que simulan cualquier acoplamiento que pudiera montarse sobre dicho eje en una máquina. Estos discos tienen una masa de 0,576 Kg cada uno, a la que hay que añadir la masa de cada sujeción de los discos que es de 0,080 kg, teniendo una masa total sobre el eje de 1,312 kg.



Figura 5.3: Disco empleado para el ensayo.

Se ha analizado el comportamiento de tres ejes de las mismas características salvo por la presencia de fisuras generadas en algunos de ellos. Estos ejes están fabricados con aluminio con un diámetro de 16 mm y una longitud de 500 mm, con una distancia entre apoyos de 350 mm. Las fisuras mecanizadas en los ejes son fisuras transversales en la zona central de los mismos.

También cabe decir que los ensayos realizados consisten en la colocación de los discos en la zona central pero situados a un lado de la fisura, en la parte más alejada del motor, aunque cercana a ella. En total, se han analizado tres ejes como los que aparecen en la figura 5.4 y que se corresponden con un:

- Eje sin fisura.
- Eje con una fisura correspondiente al 12.5 % de su diámetro.
- Eje con una fisura del 25 % de su diámetro.



Figura 5.4: Imagen de los tres ejes ensayados.

Antes de definir los ensayos a realizar es necesario calcular la velocidad crítica del eje sano para evitar trabajar cerca de ella o superarla, ya que este hecho podría provocar la rotura del eje o, en su defecto, daños en el mismo que lo inutilizarían para seguir cumpliendo su función dentro del conjunto. Esto se debe a la deformación sufrida durante la rotación, la cuál es una función de la velocidad y que presenta sus máximos cuando la velocidad de giro del eje coincide con alguna de sus velocidades críticas. De estas velocidades críticas, la primera de ellas es la que se considera más importante, aunque en algunos casos la segunda también tiene su trascendencia, debido a que son las que se pueden encontrar dentro de las velocidades de operación de la máquina, mientras que las otras son tan elevadas que no se podría llegar a alcanzarlas [33].

Para los ensayos se ha procedido a calcular la primera velocidad crítica del eje. Dicha velocidad, para un eje que lleva acoplada una sola masa 'm', siendo la del eje despreciable en comparación con la que lleva unida, se calcula aproximadamente por:

$$\omega_n = \sqrt{k/m} \quad (rad/s)$$

donde k es la constante de rigidez del eje.

Esta velocidad también puede calcularse mediante la siguiente ecuación:

$$\omega_n = \sqrt{g/\delta} \quad (rad/s)$$

donde  $\delta$  es la deformación estática producida por la masa 'm' en el punto de aplicación de la misma y g la constante de gravedad.



Por último, existe otra ecuación para calcular el valor de la velocidad crítica en rpm y donde la flecha estática  $f'$  debe estar en cm:

$$n_c = 300 \cdot \sqrt{1/f}$$

Teniendo esto en cuenta, para la configuración empleada en este proyecto, la velocidad crítica teórica es de 8026 rpm (134 Hz).

Además, se puede observar que esta velocidad crítica teórica del eje dista bastante de la velocidad alcanzada durante los ensayos (4800 rpm (80 Hz)), con lo que se evita la influencia de los efectos de dicha velocidad crítica en los resultados, incluso ante la presencia de fisuras en los ejes.

## **5.2 TRATAMIENTO DE LAS SEÑALES**

Para el tratamiento de las señales adquiridas, en este proyecto se ha empleado una serie de programas creados en MATLAB® que permiten estudiar y preparar las señales para su posterior clasificación por redes neuronales, tal y como se muestra en el diagrama de flujo de la figura 5.5.

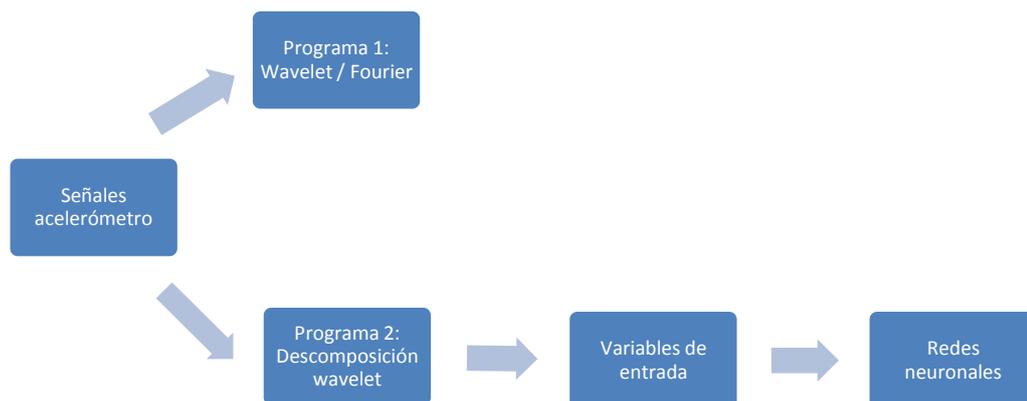


Figura 5.5: Diagrama de flujo del proceso de tratamiento de señales.

El primero de ellos consiste en un programa que calcula la descomposición wavelet de tres señales correspondientes a cada uno de los ejes ensayados utilizando una wavelet madre Daubechies 6 con un nivel de descomposición de valor 8 así como su energía, pudiéndose ver de esta forma donde están los paquetes de mayor energía, tal y como se muestra en la figura



5.6. Además, este programa también permite comparar las amplitudes de las FFT de cada tipo de eje para un determinado eje cartesiano.

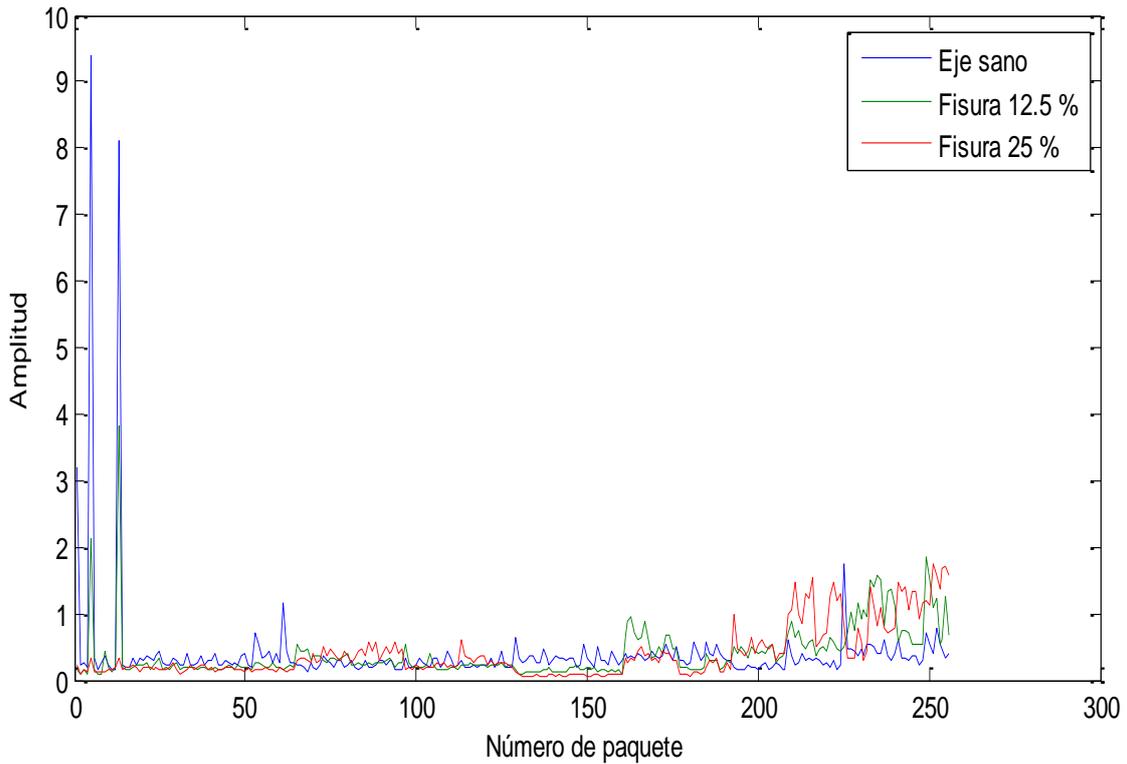


Figura 5.6: Descomposición wavelet obtenida con el programa 1.

En otro programa también creado en MATLAB® se cargan todas las señales obtenidas de los tres ensayos y luego se trabaja con los datos correspondientes al eje X. La figura 5.7 muestra un ejemplo de las señales obtenidas para cada uno de los tres ejes ensayados según el eje X.

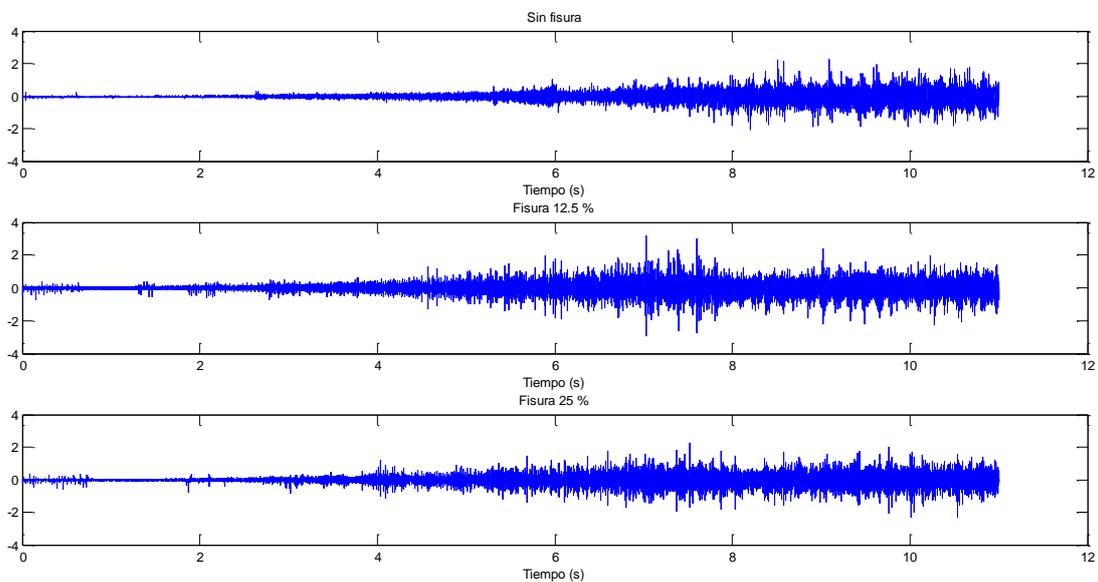


Figura 5.7: Aceleraciones medidas para el eje X correspondiente a cada tipo de eje.



Respecto al nivel de descomposición, se ha estudiado un rango de 3 a 10 y para el número de bandas de energía se ha considerado un valor de 3, siendo un valor aceptable para el correcto desarrollo del proyecto. La energía de la señal se emplea porque la presencia de la fisura provoca cambios en la rigidez que se expresan en el desplazamiento de la energía a bandas de frecuencia en las zonas de detalle.

Posteriormente, este programa realiza una descomposición wavelet empleando una wavelet madre Daubechies 6. Después se cogen los 10 valores máximos de energía de cada caso para luego comparar los resultados obtenidos de los dos casos con fisura con los correspondientes al eje sano y así obtener la variación de energía entre ellos. De esta forma se conocen los cuatro paquetes más importantes de la descomposición aplicada junto con sus correspondientes coeficientes y conseguir, de esta forma, unos mejores resultados. Además, por teoría, hay que añadir los paquetes 1 y 6 a los cuatro paquetes obtenidos del programa, aunque también se han realizado las mismas clasificaciones sin incluir dichos paquetes con el fin de comprobar si existe diferencia alguna entre incluirlos en los cálculos y no hacerlo, así como su grado de influencia en los resultados.

Por último, se integran en una variable los cuatro paquetes señalados como más significativos y los paquetes 1 y 6, si es el caso estudiado. Esta variable es la que se utilizará posteriormente como entrada a las redes neuronales para la clasificación de los casos.

Cabe decir que este desarrollo es el correspondiente a las vibraciones en el eje X, si bien para los demás ejes cartesianos se han creado programas idénticos pero utilizando en cada uno las señales de los ejes Y y Z respectivamente. Además, para cada programa hay que ir variando el intervalo de una matriz de señales según la zona del ensayo que se desee estudiar.

Por otro lado, para las redes neuronales ensayadas en el desarrollo del proyecto, se han empleado los valores por defecto que facilita el programa MATLAB®. Los valores utilizados para el entrenamiento, la validación y el test para una red de reconocimiento de patrones y con un número de neuronas ocultas igual a 20 se presentan en la tabla 5.1, mientras que para las redes probabilística y radial, los valores son los usados automáticamente por el programa.

Concepto	Porcentaje (%)	Nº de muestras
Entrenamiento	70	38
Validación	15	8
Test	15	8

Tabla 5.1: Valores de validación y test de la red de reconocimiento de patrones.



## **Capítulo 6:**

### Resultados experimentales



## **6. INTRODUCCIÓN**

En este capítulo se presentan los resultados obtenidos a partir de las señales medidas en el banco de ensayos. Primeramente se muestran una serie de gráficos que representan las aceleraciones en los tres ejes cartesianos para cada uno de los ejes ensayados. También se incluyen otras representaciones de las aceleraciones referentes a tres tomas de datos diferentes con un eje con una fisura del 12.5 % con el objetivo de compararlas entre sí.

Después se exponen los resultados de una descomposición wavelet y de una Transformada Rápida de Fourier aplicadas a una misma señal, con el fin de justificar el empleo de la descomposición wavelet en lugar de otras técnicas clásicas.

Posteriormente se presentan los resultados obtenidos de la clasificación de las señales para cada red neuronal empleada. Estos resultados se mostrarán en tablas con los porcentajes de clasificación alcanzados. Además, estos resultados se acompañan con gráficos que representan las eficiencias mostradas en estas tablas.

En último lugar se muestra el presupuesto del proyecto, donde se desglosarán los costes en los que se ha incurrido para el desarrollo de este estudio.

### **6.1 RESULTADOS PREVIOS**

En este apartado se presentan los resultados obtenidos previamente a la clasificación de las señales mediante las redes neuronales artificiales.

A continuación, en la figura 6.1 se muestran las aceleraciones correspondientes al eje X para los tres tipos de ejes ensayados. En esta figura se puede observar que, en la zona comprendida entre 0 y 4 segundos, las señales muestran una pequeña amplitud, si bien aparecen ciertos picos en los ejes fisurados que no tienen lugar en el caso de un eje sano. Por otro lado, en la zona englobada entre 4 y 8 segundos, se aprecian mayores diferencias que en la zona anterior. En este caso, los picos que aparecen para un eje sano son de menor amplitud que para los casos de ejes con fisura, siendo los picos referentes al eje con una fisura del 12.5 % de mayor importancia que en el caso de un eje con una fisura del 25 %. Por último, para el intervalo entre 8 y 11 segundos y correspondiente a la zona de velocidad constante, no se distinguen grandes diferencias entre los tres casos.

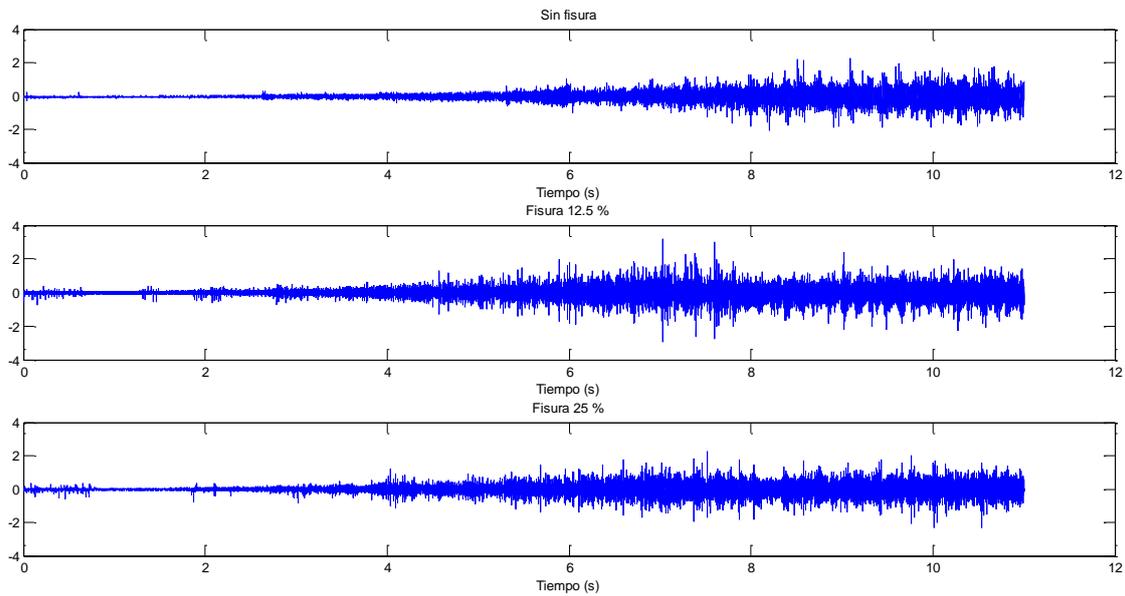


Figura 6.1: Aceleraciones medidas para el eje X correspondientes a cada tipo de eje.

Seguidamente, en la figura 6.2 se pueden comparar las aceleraciones del eje Y medidas para los tres tipos de ensayos realizados. En la primera zona (0 – 4 segundos), igual que ocurría en el caso del eje X, apenas aparecen perturbaciones que permitan diferenciar algún tipo de eje. Para la segunda zona, hasta 8 segundos, se puede distinguir el eje sano de los ejes fisurados, pero, por el contrario, existe una gran analogía entre ambos casos salvo por la presencia de algunos picos de mayor amplitud para una fisura del 12.5 %. Respecto a la tercera zona, se observa que las tres señales se asemejan bastante, como sucedía con el eje X.

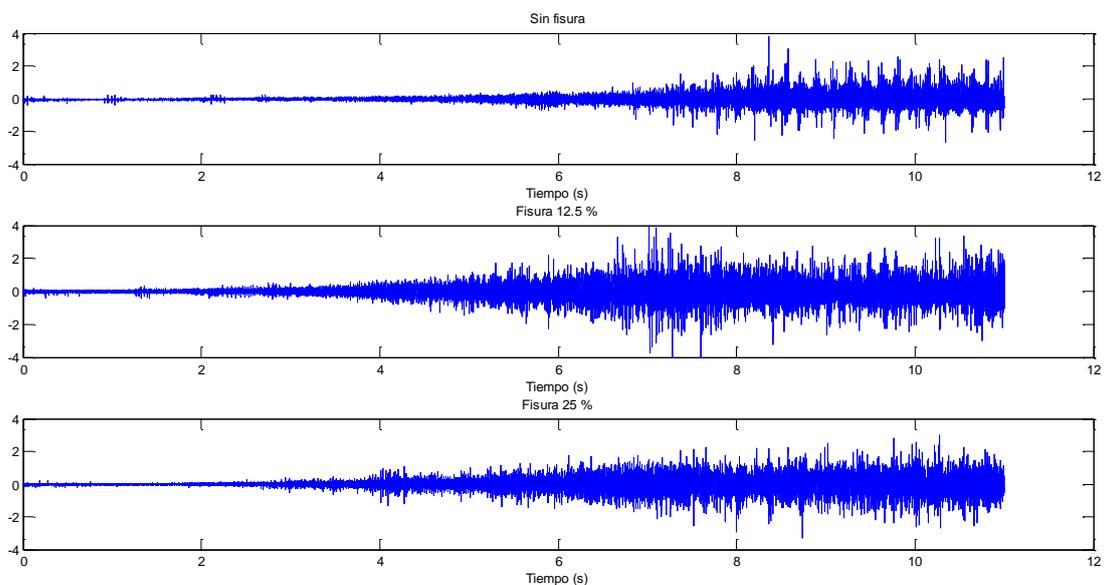


Figura 6.2: Aceleraciones medidas para el eje Y correspondientes a los ejes ensayados.



Por último, en la figura 6.3 se pueden comparar los resultados de las aceleraciones en el eje Z medidas para los tres casos estudiados. Nuevamente, para la primera zona, no se aprecian diferencias significativas, mientras que en la segunda zona sí se observa otra vez desigualdad entre las señales. En esta zona central cabe decir que el caso en el que aparece un menor número de picos es el correspondiente a una fisura del 25 %, en tanto que en el eje sano se aprecia una zona cercana a 6 segundos que no tiene lugar en los ejes fisurados, mientras que en la zona comprendida entre 7 y 8 segundos aparecen una serie de picos de mayor amplitud para una fisura del 12.5 % que no tienen lugar en las otras dos señales. En la última zona, no hay muchas diferencias importantes entre un eje sano y otro con una fisura del 12.5 %, aunque sus señales presentan una mayor amplitud que la perteneciente al eje con una fisura del 25 %.

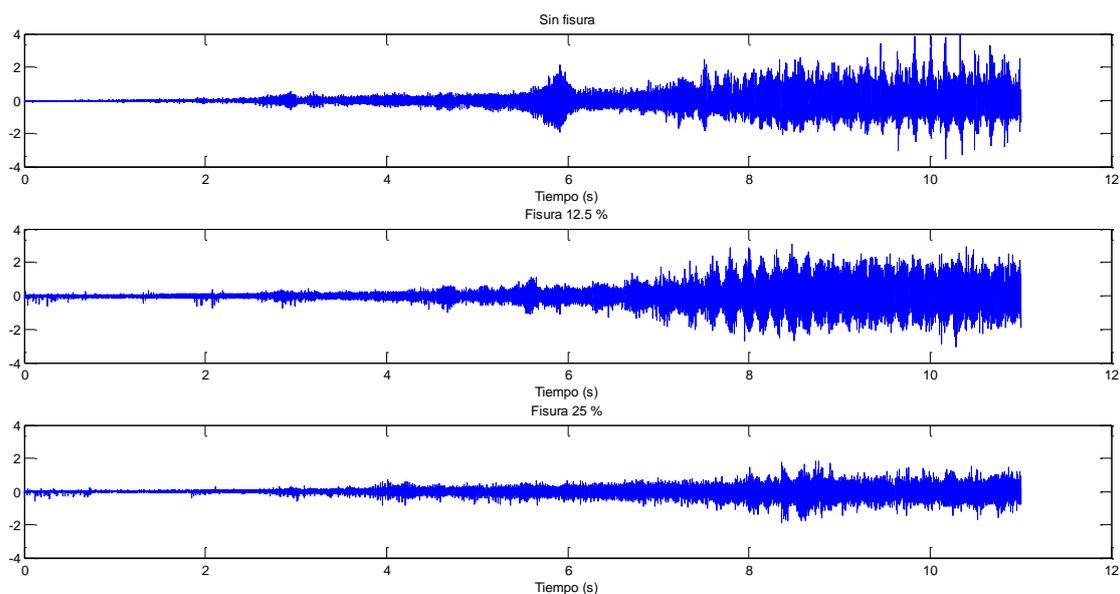


Figura 6.3: Aceleraciones medidas para el eje Z correspondientes a los ejes ensayados.

A continuación se muestran en las figuras 6.4, 6.5 y 6.6 las aceleraciones medidas para un eje que presenta una fisura del 12.5 % y tomadas en tres ensayos diferentes. En ellas se puede observar que las señales medidas son muy parecidas, si bien presentan ciertas diferencias en algunos puntos, como puede ser el caso del eje Z, donde se puede ver que existe una zona alrededor de los 6 segundos que sólo aparece en una de las señales. Esta es otra de las razones por las que es necesario clasificar las señales mediante otros métodos que puedan mostrar patrones de comportamiento que sigan las señales de un mismo grupo, puesto que, como se acaba de comentar, existen ciertas diferencias entre señales del mismo grupo.

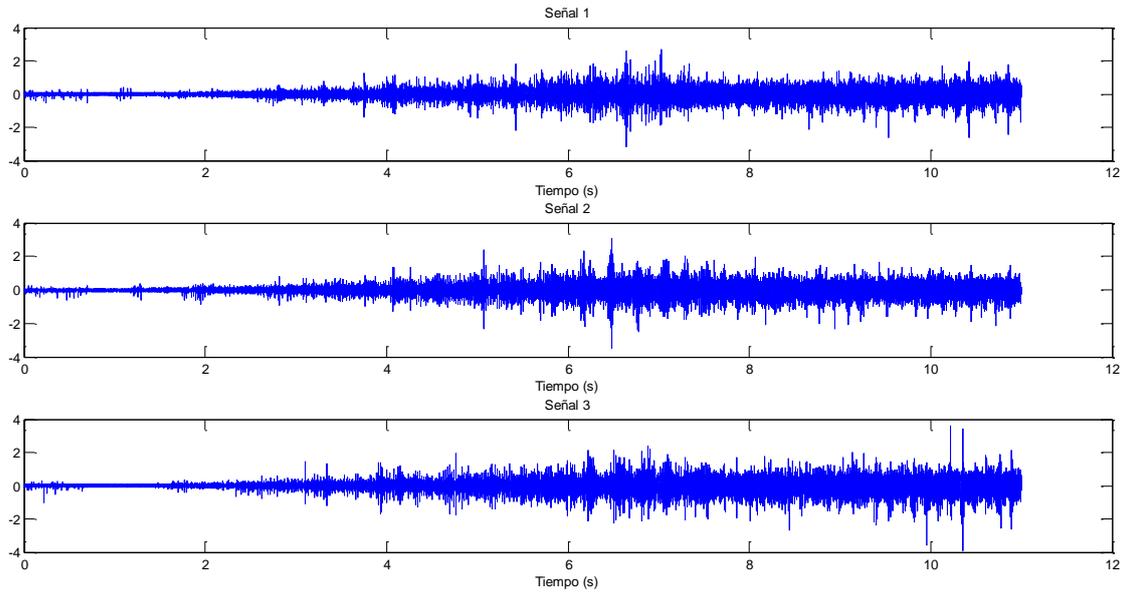


Figura 6.4: Señales de aceleración según el eje X para un eje con una fisura del 12.5 %.

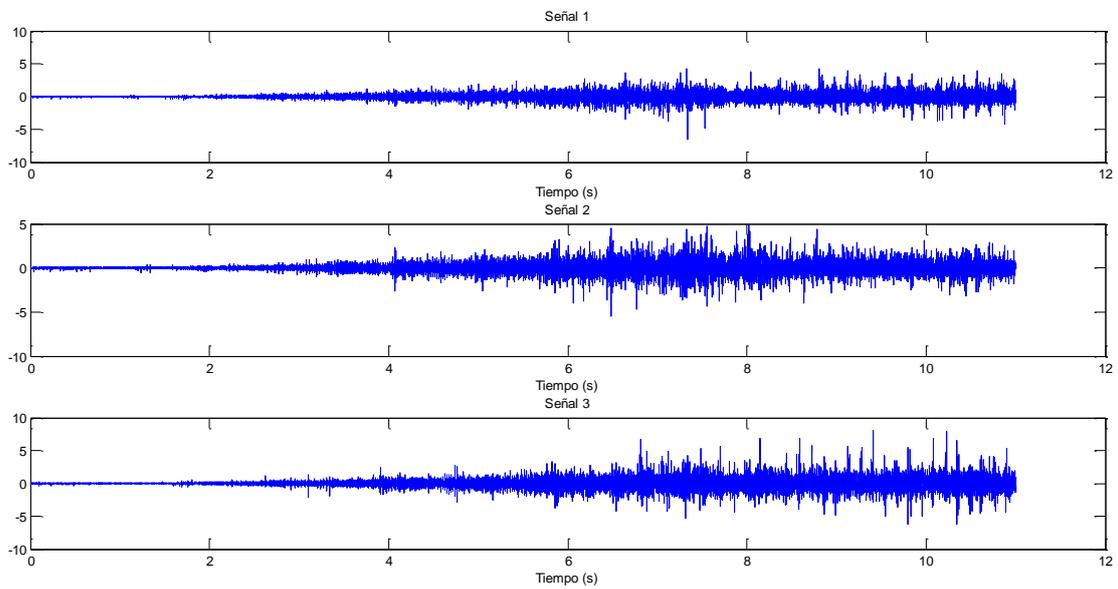


Figura 6.5: Señales de aceleración según el eje Y para un eje sano con una fisura del 12.5 %.

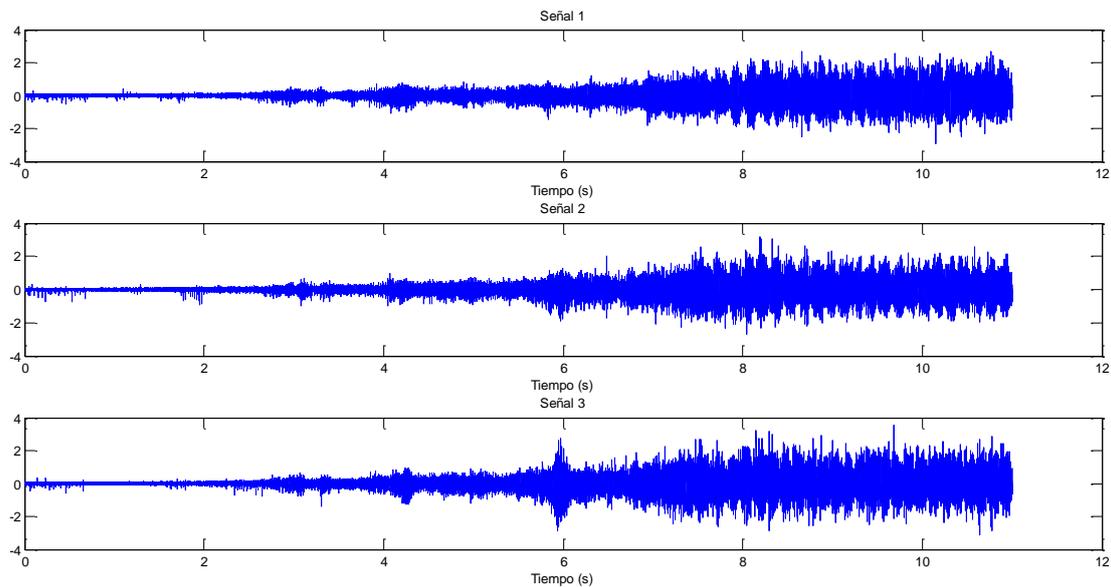


Figura 6.6: Señales de aceleración según el eje Z para un eje sano con una fisura del 12.5 %.

A continuación, las figuras 6.7 y 6.8 muestran los gráficos generados por el programa creado en MATLAB® para el cálculo de la energía de la transformada wavelet, y que se corresponden con un nivel de descomposición wavelet de grado 8 y con la FFT de las mismas señales respectivamente, con el fin de averiguar si el análisis wavelet en este caso aporta mayor información que la FFT, como ya se ha demostrado en el estudio de otros elementos rotativos.

En la figura 6.7, se presenta la amplitud de la energía para cada uno de los diferentes paquetes obtenidos de realizar una descomposición wavelet de grado 8 (256 paquetes en total) a una señal correspondiente a cada uno de los tres ejes ensayados. En esta figura, se observa que existen en la parte inicial dos picos de gran importancia correspondientes al eje sano, en los que los paquetes pertenecientes a este eje poseen una mayor energía que los del eje con la fisura del 12.5 % y éstos, a su vez, presentan una mayor energía que los del eje con la fisura del 25 %. También se aprecia que en la zona final, en el intervalo comprendido entre los paquetes 200 y 256 aproximadamente, existen zonas donde los niveles de energía entre los tres ejes ensayados presentan diferencias apreciables que pueden ayudar a la posterior clasificación mediante el empleo de las redes neuronales artificiales.

En la figura 6.8, se calcula la FFT para cada una de las señales empleadas en la figura 6.7. En dicha figura, se puede apreciar que, únicamente existen picos de gran amplitud en frecuencias cercanas a 1800 y 2000 Hz aproximadamente, pero, al contrario de lo que sucedía en el caso anterior con la descomposición wavelet, estos picos no muestran una gran diferencia entre los tres eje simultáneamente debido a que siempre existen dos ejes con amplitudes similares. También aparecen otros picos de menor importancia a bajas frecuencias y entre 750 y 1000 Hz. Estas diferencias entre ambos análisis hacen que la descomposición wavelet sea más adecuada para la clasificación de las señales de estudio de este proyecto.

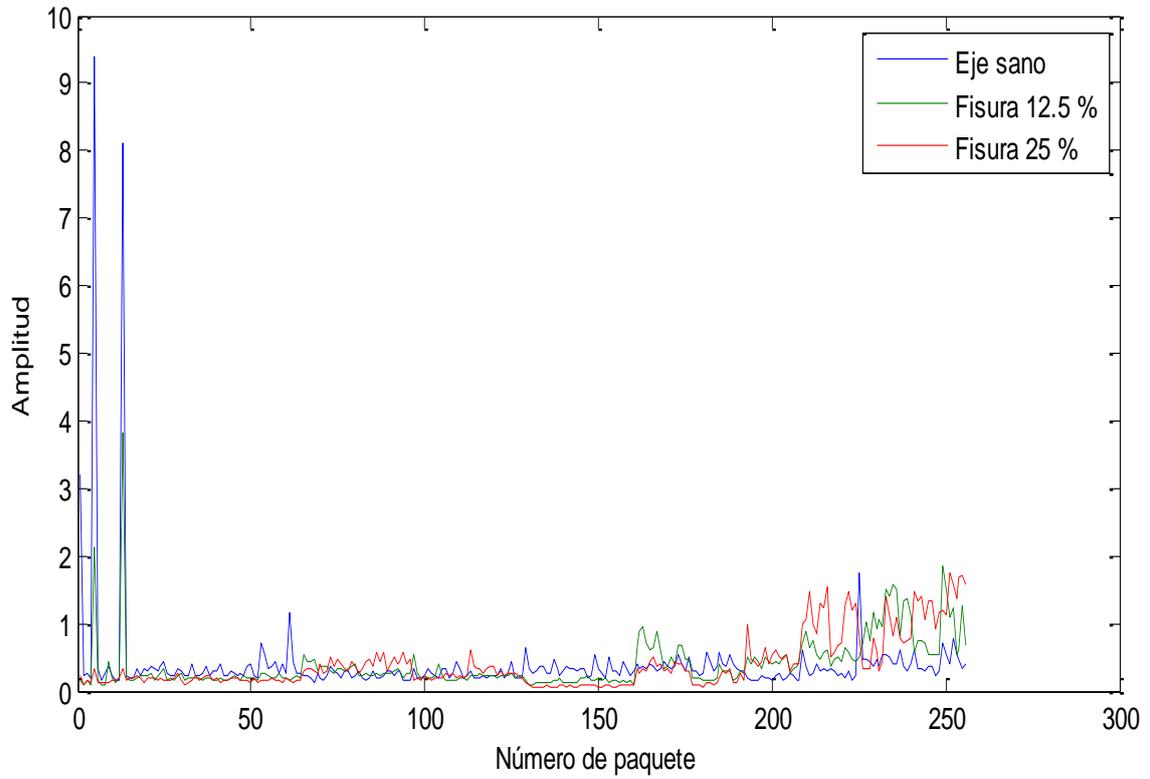


Figura 6.7: Descomposición wavelet de 8 niveles.

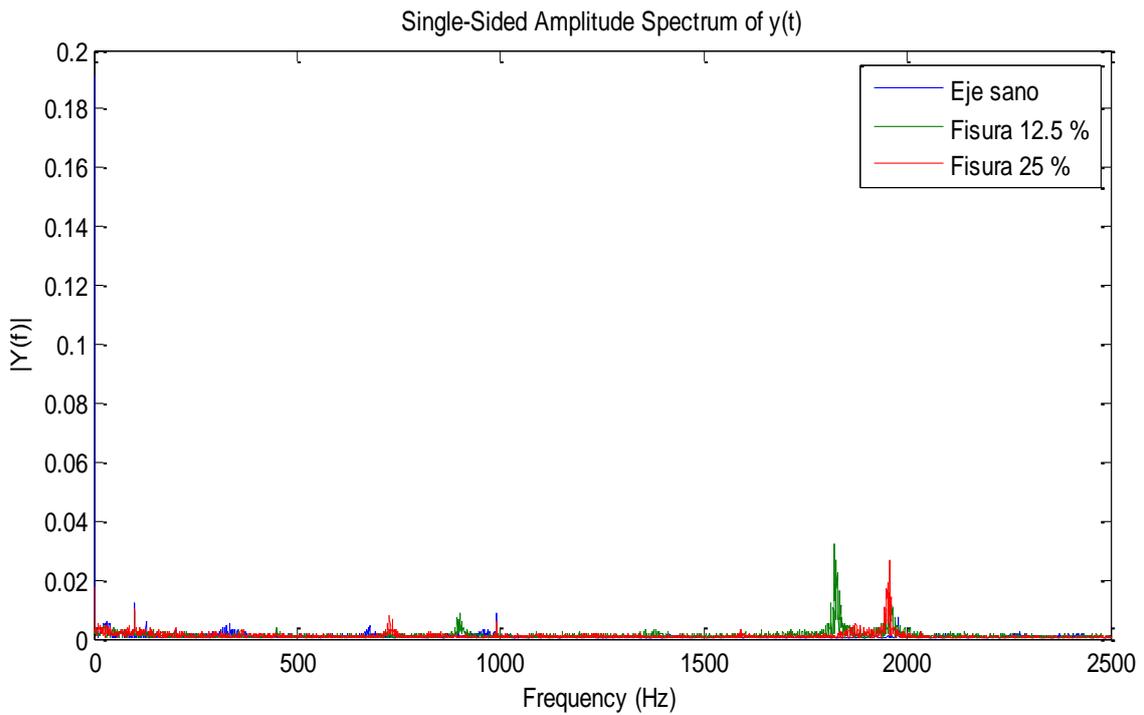


Figura 6.8: FFT de una de las señales adquiridas.



**6.2 OBTENCIÓN DE LOS PAQUETES DE ENERGÍA ÓPTIMOS**

En las tablas 6.1, 6.2 y 6.3 aparecen los paquetes óptimos obtenidos para los tres ejes cartesianos según el nivel de descomposición wavelet elegido (de 3 a 10) y cada una de las zonas en las que se ha dividido el ensayo (ver figura 5.1). Como puede verse, el tamaño de los paquetes es cada vez menor a medida que se aumenta el nivel de descomposición y disminuye aproximadamente a la mitad cuanto mayor es el grado de descomposición.

Eje X							
Nivel de descomposición	Paquetes óptimos	Zona A		Zona B		Zona C	
		Paquete	Tamaño	Paquete	Tamaño	Paquete	Tamaño
3	Primero	0	2509	7	2509	7	1884
	Segundo	7		1		1	
	Tercero	5		0		3	
	Cuarto	6		0		0	
4	Primero	0	1260	14	1260	14	947
	Segundo	14		10		14	
	Tercero	10		2		3	
	Cuarto	15		2		6	
5	Primero	0	635	29	635	31	479
	Segundo	28		29		29	
	Tercero	20		20		6	
	Cuarto	29		31		7	
6	Primero	0	323	62	323	13	245
	Segundo	56		58		13	
	Tercero	40		63		13	
	Cuarto	58		59		15	
7	Primero	0	167	124	167	26	128
	Segundo	112		116		30	
	Tercero	81		116		2	
	Cuarto	80		125		30	
8	Primero	0	89	0	89	52	69
	Segundo	227		238		60	
	Tercero	226		0		4	
	Cuarto	160		55		60	
9	Primero	0	50	0	50	8	40
	Segundo	448		0		104	
	Tercero	344		320		104	
	Cuarto	320		320		120	
10	Primero	0	30	0	30	0	25
	Segundo	896		640		48	
	Tercero	512		0		16	
	Cuarto	992		768		209	

Tabla 6.1: Paquetes óptimos correspondientes al eje X.



Eje Y							
Nivel de descomposición	Paquetes óptimos	Zona A		Zona B		Zona C	
		Paquete	Tamaño	Paquete	Tamaño	Paquete	Tamaño
3	Primero	0	2509	7	2509	0	1884
	Segundo	7		0		7	
	Tercero	6		1		6	
	Cuarto	5		1		4	
4	Primero	0	1260	14	1260	0	947
	Segundo	14		0		15	
	Tercero	15		0		15	
	Cuarto	10		3		9	
5	Primero	0	635	31	635	1	479
	Segundo	29		0		0	
	Tercero	28		0		31	
	Cuarto	31		28		26	
6	Primero	0	323	58	323	3	245
	Segundo	56		62		1	
	Tercero	40		59		55	
	Cuarto	62		1		53	
7	Primero	0	167	0	167	6	128
	Segundo	112		0		2	
	Tercero	113		124		125	
	Cuarto	81		124		106	
8	Primero	0	89	0	89	12	69
	Segundo	224		4		4	
	Tercero	232		0		0	
	Cuarto	225		12		0	
9	Primero	0	50	0	50	24	40
	Segundo	448		8		8	
	Tercero	440		8		0	
	Cuarto	384		9		0	
10	Primero	0	30	0	30	48	25
	Segundo	896		0		16	
	Tercero	768		0		16	
	Cuarto	512		19		0	

Tabla 6.2: Relación de paquetes óptimos para el eje Y.



Eje Z							
Nivel de descomposición	Paquetes óptimos	Zona A		Zona B		Zona C	
		Paquete	Tamaño	Paquete	Tamaño	Paquete	Tamaño
3	Primero	0	2509	5	2509	5	1884
	Segundo	1		5		1	
	Tercero	7		0		0	
	Cuarto	1		7		6	
4	Primero	0	1260	6	1260	3	947
	Segundo	14		10		0	
	Tercero	1		10		11	
	Cuarto	1		14		0	
5	Primero	0	635	0	635	23	479
	Segundo	28		6		12	
	Tercero	20		21		1	
	Cuarto	2		23		0	
6	Primero	0	323	13	323	13	245
	Segundo	56		1		25	
	Tercero	11		4		3	
	Cuarto	40		24		15	
7	Primero	0	167	27	167	26	128
	Segundo	11		2		30	
	Tercero	11		2		30	
	Cuarto	22		0		6	
8	Primero	0	89	55	89	52	69
	Segundo	21		55		12	
	Tercero	22		54		60	
	Cuarto	21		23		4	
9	Primero	0	50	0	50	24	40
	Segundo	108		8		104	
	Tercero	45		0		120	
	Cuarto	47		106		120	
10	Primero	0	30	0	30	0	25
	Segundo	224		16		16	
	Tercero	192		16		209	
	Cuarto	192		512		241	

Tabla 6.3: Paquetes óptimos referentes al eje Z.



### **6.3 RESULTADOS DEL PROCESO DE CLASIFICACIÓN**

En este apartado se exponen los resultados obtenidos para cada una de las redes neuronales estudiadas y que se corresponden con una red neuronal probabilística, otra de base radial y una tercera red de reconocimiento de patrones. Para estas redes se han empleado, como datos de entrada, los paquetes mostrados en las tablas 6.1, 6.2 y 6.3, obteniéndose como salida los resultados de la clasificación de las redes neuronales.

En cada una de las subsecciones de este apartado se muestran en una tabla los porcentajes de clasificación para cada eje cartesiano y cada nivel de descomposición, así como también se diferencia entre aquellos a los que se adicionan los paquetes 1 y 6 y aquellos en los que no se incluyen dichos paquetes. Además, los resultados se presentan para las tres zonas en las que se dividen los ensayos y para cada tipo de eje. También se expresan las eficiencias en la clasificación basadas en cada zona y para cada uno de los tres tipos de ejes ensayados. Finalmente, se tiene la eficiencia general obtenida en cada zona y otra global que tiene en cuenta todos los resultados anteriores. Asimismo, se incluyen gráficos que representan las eficiencias de las tablas anteriores.

#### **6.3.1 RED PROBABILÍSTICA**

##### **6.3.1.1 Red probabilística incluyendo los paquetes 1 y 6**

A continuación se presentan los resultados de los porcentajes de clasificación relativos a una red probabilística empleando los paquetes mostrados en las tablas 6.1, 6.2 y 6.3 y los paquetes 1 y 6 (*c.p.*) en los casos en los que no aparezcan como paquetes óptimos. Estos resultados aparecen en tablas según el eje cartesiano y acompañados de los respectivos gráficos.



EJE X					
Nivel de descomposición		Zona A	Zona B	Zona C	Eficiencia
3	Eje sano	100	100	100	100
	Fisura 12.5 %	16.67	100	100	72.22
	Fisura 25%	100	100	100	100
	Eficiencia	72.22	100	100	90.74
4	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
5	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
6	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
7	Eje sano	100	100	100	100
	Fisura 12.5 %	100	83.33	100	94.44
	Fisura 25%	100	83.33	100	94.44
	Eficiencia	100	88.89	100	96.30
8	Eje sano	100	100	100	100
	Fisura 12.5 %	100	61.11	100	87.04
	Fisura 25%	100	94.4	100	98.15
	Eficiencia	100	85.18	100	95.06
9	Eje sano	100	88.89	100	96.30
	Fisura 12.5 %	100	61.11	100	87.04
	Fisura 25%	100	88.89	100	96.30
	Eficiencia	100	79.63	100	93.21
10	Eje sano	100	88.89	100	96.30
	Fisura 12.5 %	94.44	61.11	100	85.18
	Fisura 25%	88.89	94.44	100	94.44
	Eficiencia	94.44	81.48	100	91.97
<b>Eficiencia total</b>		<b>95.83</b>	<b>91.90</b>	<b>100</b>	<b>95.91</b>

Tabla 6.4: Resultados de clasificación de una red probabilística para el eje X (c.p.).

La figura 6.9 muestra los resultados de la tabla 6.4 de una manera más intuitiva. En ella se puede ver cómo en la zona C, correspondiente con la zona de velocidad constante, es la que presenta una eficiencia global mayor, de valor 100 %, mientras que la peor zona para la clasificación es la zona B (91.90 %), aunque el rendimiento obtenido en este caso es bastante bueno. Además, se puede notar que en esta segunda zona los resultados son peores a partir de un nivel de descomposición superior a 7, algo que no sucede en los demás casos.

En cuanto a los resultados por tipo de eje, se puede apreciar en la figura 6.10 que la eficiencia obtenida para un eje sano es la mejor de los tres, aunque la alcanzada por el eje con



una fisura del 25 % también es elevada. Por el contrario, los peores resultados se consiguen para una fisura del 12.5 % y sólo se logra la máxima eficiencia para los niveles de descomposición 4, 5 y 6, por lo que se puede decir que, para el estudio en el eje X, estos valores de descomposición son los adecuados para este tipo de red neuronal.

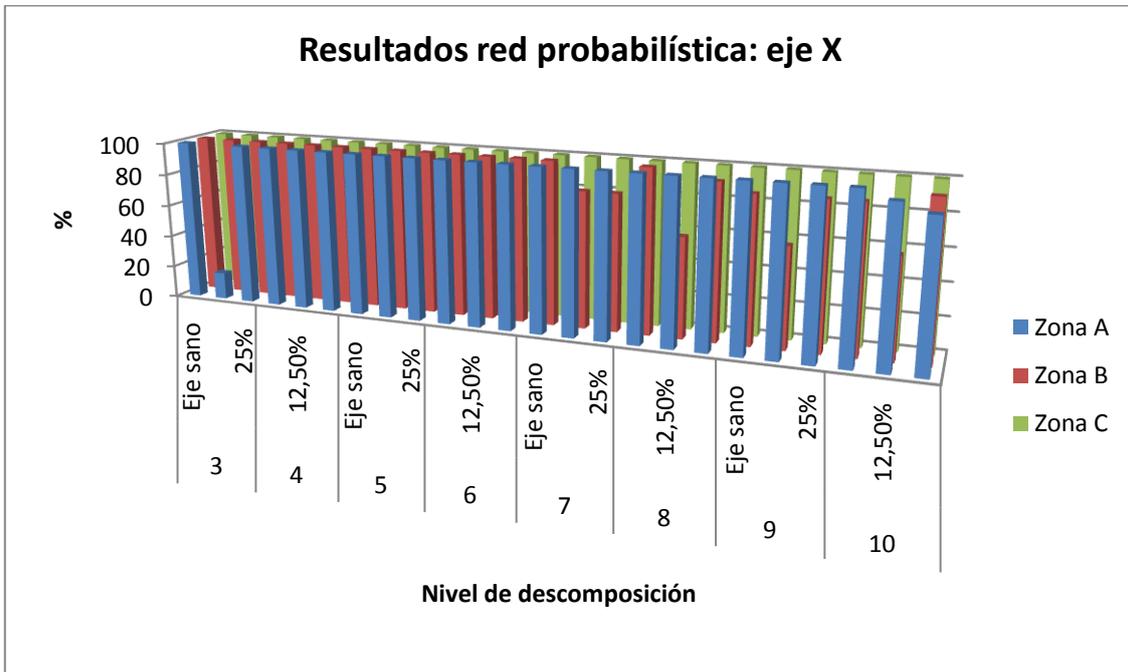


Figura 6.9: Gráfico de clasificación de una red probabilística para el eje X (c.p.).

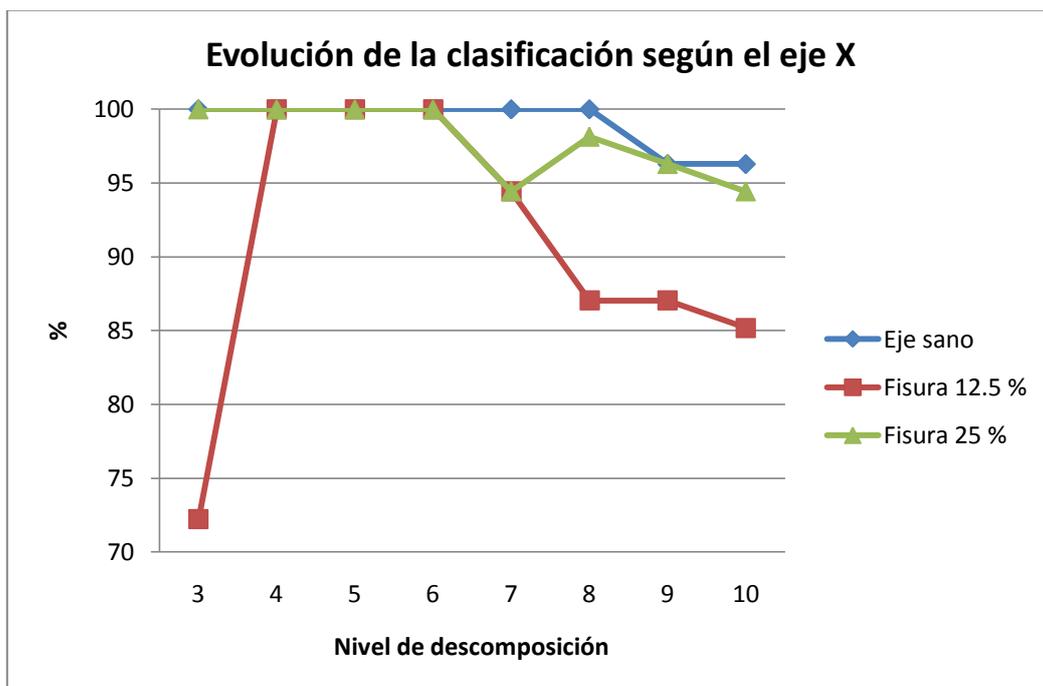


Figura 6.10: Gráfico de la eficiencia de clasificación según el eje X de una red probabilística (c.p.).



La tabla 6.5 muestra los resultados obtenidos para el eje Y con una red probabilística:

		EJE Y			
Nivel de descomposición		Zona A	Zona B	Zona C	Eficiencia
3	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
4	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
5	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
6	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
7	Eje sano	100	100	100	100
	Fisura 12.5 %	94.44	66.67	100	87.04
	Fisura 25%	94.44	72.22	100	88.89
	Eficiencia	96.29	79.63	100	91.97
8	Eje sano	100	100	100	100
	Fisura 12.5 %	94.44	55.56	100	83.33
	Fisura 25%	94.44	100	100	98.15
	Eficiencia	96.29	85.19	100	93.83
9	Eje sano	100	100	100	100
	Fisura 12.5 %	94.44	38.89	100	77.78
	Fisura 25%	88.89	94.44	100	94.44
	Eficiencia	94.44	77.78	100	90.74
10	Eje sano	100	94.44	100	98.15
	Fisura 12.5 %	94.44	83.33	100	92.59
	Fisura 25%	100	50	100	83.33
	Eficiencia	98.15	75.92	100	91.36
<b>Eficiencia total</b>		<b>98.15</b>	<b>89.81</b>	<b>100</b>	<b>95.99</b>

Tabla 6.5: Resultados de clasificación según el eje Y para una red probabilística (c.p.).

En la figura 6.11 se observa que nuevamente los mejores resultados se consiguen en la zona C (100 %) mientras que los peores se logran en la zona B (89.91 %). Por otro lado, la zona A muestra una eficiencia de clasificación muy elevada y cercana al 100 % (98.15%). Además, como sucedía para el caso del eje X, los resultados obtenidos son peores cuando el nivel de descomposición empleado es superior a 6.



Respecto a los resultados por tipo de eje, mostrados en la figura 6.12, se observa que de nuevo el eje sano es el que obtiene mejores resultados con valores del 100 % salvo en un nivel de descomposición de 10, donde disminuye su eficiencia en torno a un 2%. Para los otros dos ejes con fisuras, el eje con fisura del 12.5 % se muestra, otra vez, como el más problemático a la hora de su clasificación, aunque cabe decir que los tres ejes se consiguen clasificar perfectamente para los cuatro primeros niveles de descomposición empleados.

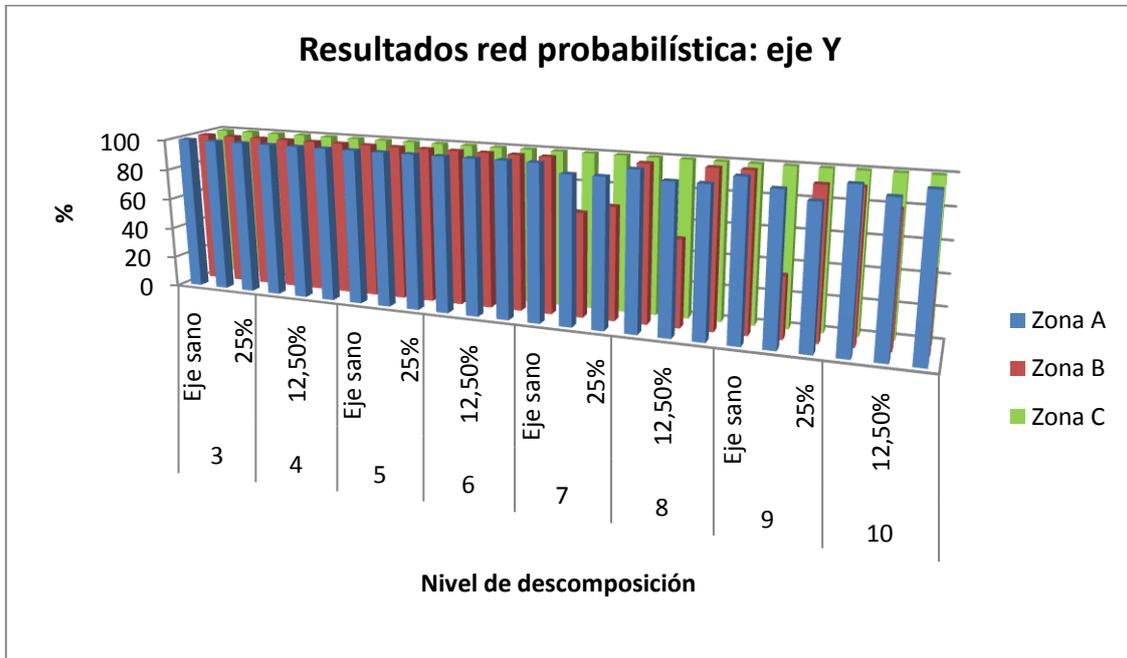


Figura 6.11: Gráfico de clasificación de una red probabilística según el eje Y (c.p.).

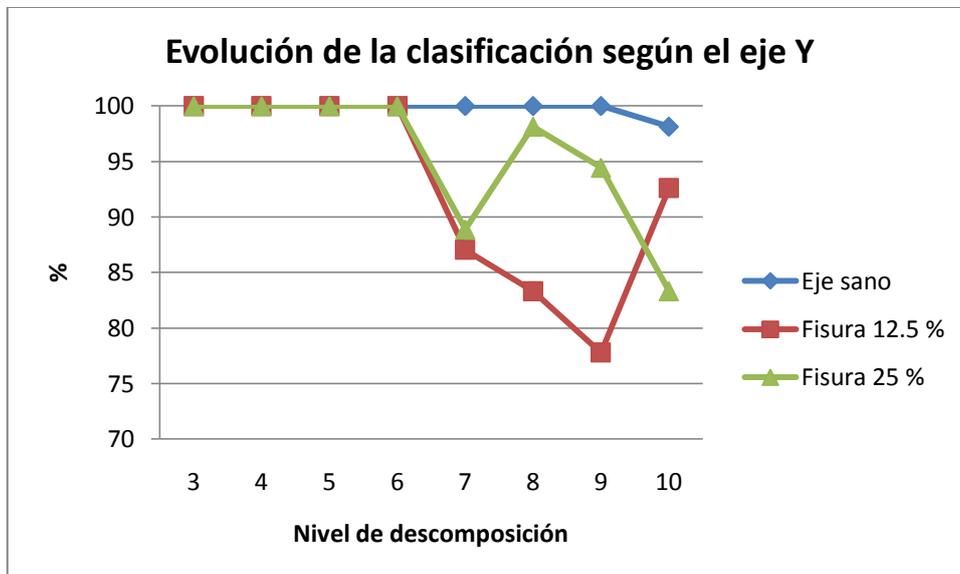


Figura 6.12: Evolución de la clasificación del eje Y para una red probabilística (c.p.).



Los resultados correspondientes al eje Z para la red neuronal probabilística se presentan en la tabla 6.6:

Nivel de descomposición	EJE Z				Eficiencia
		Zona A	Zona B	Zona C	
3	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
4	Eje sano	100	100	100	100
	Fisura 12.5 %	100	94.44	100	98.15
	Fisura 25%	100	100	100	100
	Eficiencia	100	98.15	100	99.38
5	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
6	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	94.44	100	98.15
	Eficiencia	100	98.15	100	99.38
7	Eje sano	100	100	100	100
	Fisura 12.5 %	94.44	100	94.44	96.29
	Fisura 25%	100	100	94.44	98.15
	Eficiencia	98.15	100	96.29	98.15
8	Eje sano	100	88.89	100	96.30
	Fisura 12.5 %	100	50	94.44	81.48
	Fisura 25%	94.44	100	88.89	94.44
	Eficiencia	98.15	79.63	94.44	90.74
9	Eje sano	100	77.78	100	92.59
	Fisura 12.5 %	83.33	77.78	66.67	75.93
	Fisura 25%	100	83.33	94.44	92.59
	Eficiencia	94.44	79.63	87.04	87.04
10	Eje sano	100	61.11	100	87.04
	Fisura 12.5 %	88.89	94.44	83.33	88.89
	Fisura 25%	94.44	61.11	94.44	83.33
	Eficiencia	94.44	72.22	92.59	86.42
<b>Eficiencia total</b>		<b>98.15</b>	<b>90.97</b>	<b>96.30</b>	<b>95.14</b>

Tabla 6.6: Resultados de clasificación de una red probabilística según el eje Z (c.p.).

En este caso, se tiene que las zonas A y C son las que presentan el mejor porcentaje de clasificación, 98.15 % y 96.30 % respectivamente, según muestra la figura 6.13 pero al contrario de lo que ocurría en los dos casos anteriores, ahora es la zona A y no la C la que clasifica mejor. En cuanto al nivel de descomposición, hay que decir que los resultados



empeoran a partir de un nivel de descomposición igual a 8 o superior, especialmente para la zona B.

En referencia a los resultados logrados para los distintos ejes y mostrados en la figura 6.14, se tiene que el eje sin fisura sigue siendo el que mejor clasifica y el eje con una fisura del 12.5 % es el que presenta peores resultados. De todas formas, para los niveles de descomposición 3 a 7, ambos inclusive, se logran unos porcentajes de clasificación muy altos cercanos al 100 %.

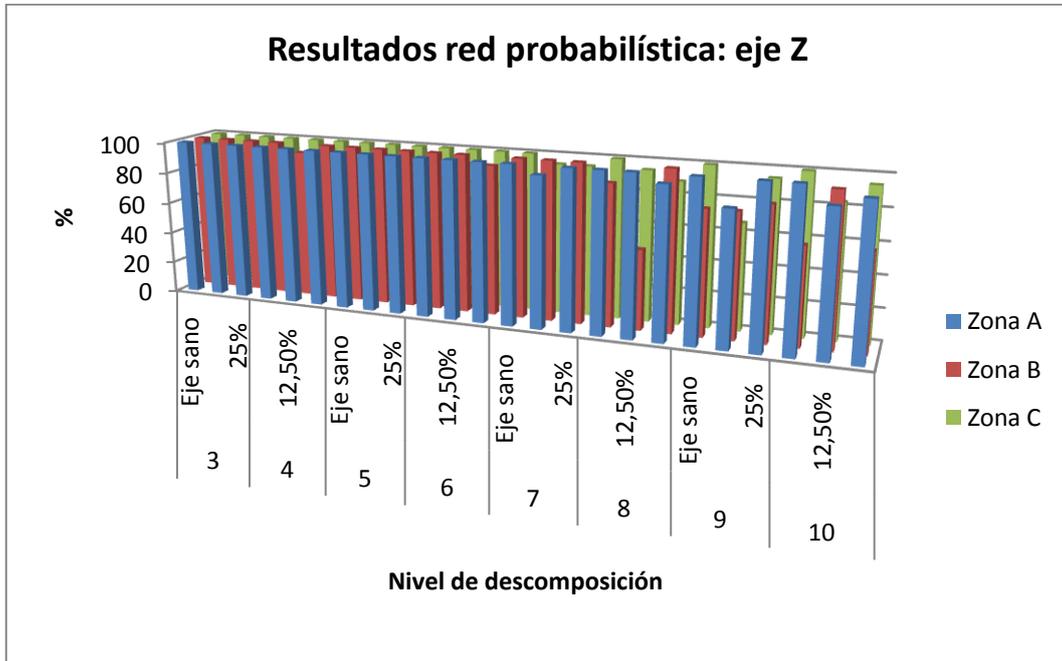


Figura 6.13: Gráfico de clasificación para el eje Z de una red probabilística (c.p.).

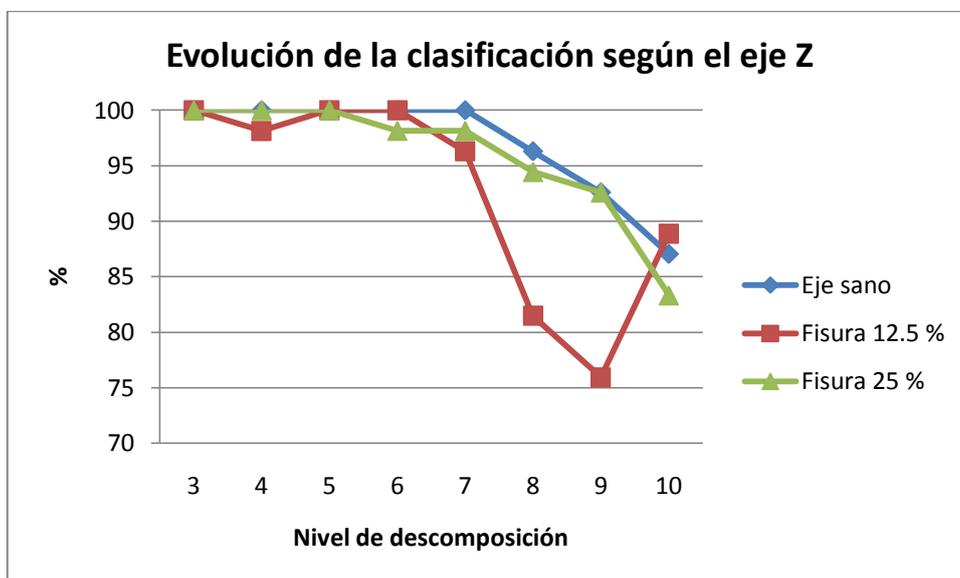


Figura 6.14: Eficiencia de la clasificación según el eje Z de una red probabilística (c.p.).



A tenor de los resultados vistos hasta ahora se puede decir que la zona en régimen constante (zona C) es la que mejores resultados consigue, si bien, para el último caso estudiado, correspondiente al eje Z, la zona A logra un mejor porcentaje de clasificación. La peor zona de las tres es la zona B, cuyos resultados son los peores en los tres casos. También se puede decir que los cuatro primeros niveles de descomposición empleados son que se comportan mejor en estos casos.

También puede decirse que el eje sano es el que logra unas mayores eficiencias de clasificación, al contrario de lo que sucede con el eje que presenta una fisura del 12.5 %, que es el que obtiene los peores resultados, aunque para los niveles de descomposición 3, 4, 5 y 6 se alcanzan buenos resultados para los tres ejes ensayados, con valores cercanos o iguales al 100 %.



**6.3.1.2 Red probabilística sin incluir los paquetes 1 y 6**

A continuación, se presentan los resultados obtenidos de la clasificación mediante una red probabilística, donde se han incluido los paquetes los resultados mostrados en las tablas 6.1, 6.2 y 6.3 pero sin incluir esta vez los paquetes 1 y 6 (*s.p.*), excepto en aquellos casos en los que aparezcan como paquetes óptimos. Estos porcentajes de clasificación se resumen en las tablas y gráficos que aparecen en este apartado.

EJE X					
Nivel de descomposición		Zona A	Zona B	Zona C	Eficiencia
3	Eje sano	100	100	100	100
	Fisura 12.5 %	100	94.44	100	98.15
	Fisura 25%	100	77.78	100	92.59
	Eficiencia	100	90.74	100	96.91
4	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
5	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
6	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
7	Eje sano	100	100	100	100
	Fisura 12.5 %	100	77.78	100	92.59
	Fisura 25%	100	83.33	100	94.44
	Eficiencia	100	87.04	100	95.68
8	Eje sano	100	100	100	100
	Fisura 12.5 %	100	61.11	100	87.04
	Fisura 25%	100	94.44	100	98.15
	Eficiencia	100	85.18	100	95.06
9	Eje sano	100	88.89	100	96.30
	Fisura 12.5 %	100	61.11	100	87.04
	Fisura 25%	100	88.89	100	96.30
	Eficiencia	100	79.63	100	93.21
10	Eje sano	100	88.89	100	96.30
	Fisura 12.5 %	94.44	61.11	100	85.18
	Fisura 25%	88.89	94.44	100	94.44
	Eficiencia	94.44	81.48	100	91.97
<b>Eficiencia total</b>		<b>99.31</b>	<b>90.51</b>	<b>100</b>	<b>96.60</b>

Tabla 6.7: Resultados de clasificación de una red probabilística para el eje X (*s.p.*).



Tal y como muestra la figura 6.15, las zonas A y C clasifican perfectamente en todo el rango de descomposiciones realizadas pero, sin embargo, la zona B, con una eficiencia de clasificación del 90.51 %, empeora su rendimiento con niveles de descomposición de superiores a 6.

En la figura 6.16 se sigue observando que el eje con una fisura del 12.5 % es el que se clasifica peor, mientras que el eje sano continúa ofreciendo los mejores resultados y el eje con fisura del 25 % presenta unos porcentajes muy elevados de eficiencia. Los grados de descomposición más adecuados para una correcta clasificación de todas las señales se corresponden con los niveles 4, 5 y 6, tal y como ocurría para el eje X incluyendo los paquetes 1 y 6.

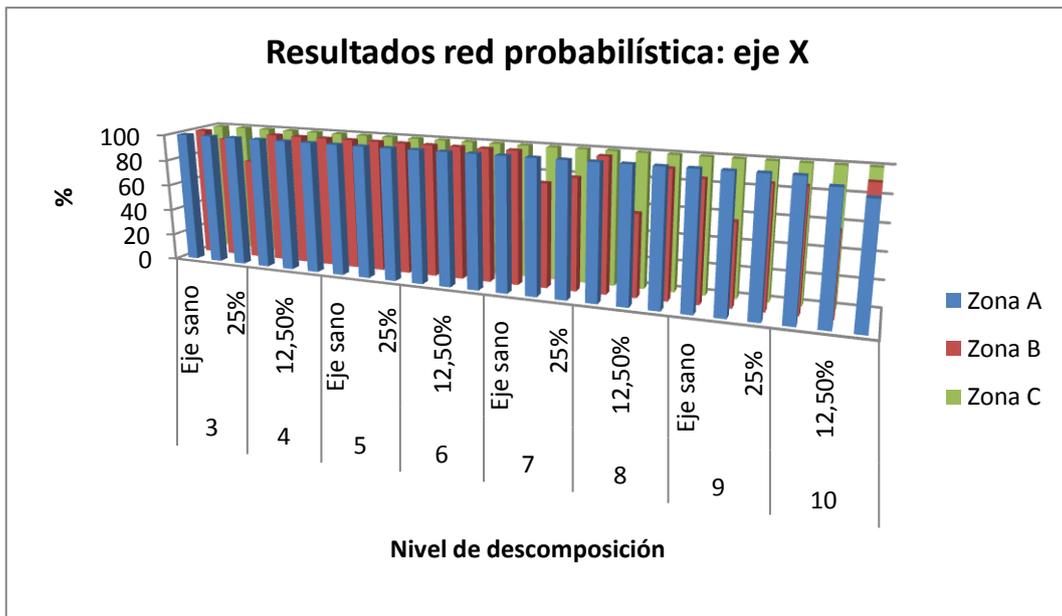


Figura 6.15: Gráfico de clasificación de una red probabilística según el eje X (s.p.).

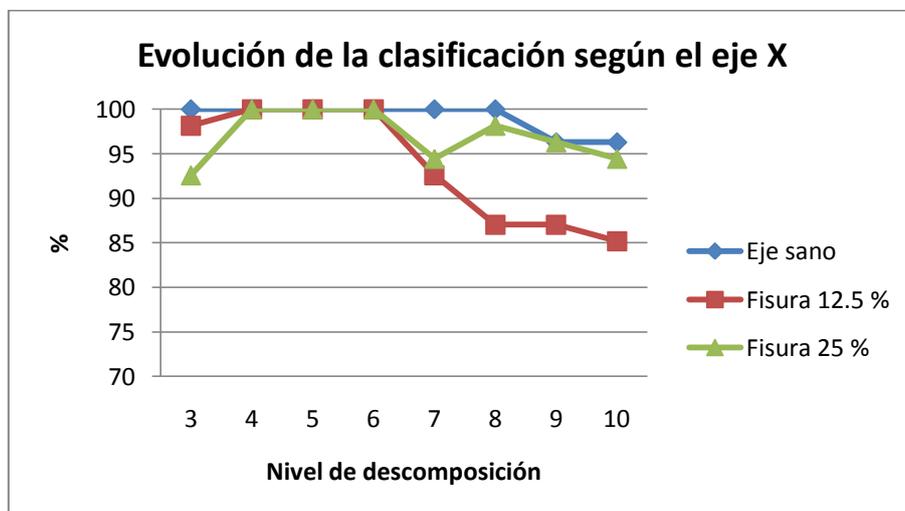


Figura 6.16: Gráfico de la eficiencia de clasificación según el eje X de una red probabilística (s.p.).



La tabla 6.8 resume los porcentajes de clasificación conseguidos por la red probabilística para el eje Y:

		EJE Y			
Nivel de descomposición		Zona A	Zona B	Zona C	Eficiencia
3	Eje sano	100	100	100	100
	Fisura 12.5 %	100	94.44	100	98.15
	Fisura 25%	100	100	100	100
	Eficiencia	100	98.15	100	99.38
4	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
5	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
6	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	94.44	98.15
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	98.15	99.38
7	Eje sano	100	100	100	100
	Fisura 12.5 %	94.44	50	94.44	79.63
	Fisura 25%	94.44	66.67	100	87.04
	Eficiencia	96.29	72.22	98.15	88.89
8	Eje sano	100	100	100	100
	Fisura 12.5 %	94.44	44.44	100	79.63
	Fisura 25%	94.44	100	100	98.15
	Eficiencia	96.29	81.48	100	92.59
9	Eje sano	100	100	100	100
	Fisura 12.5 %	94.44	38.89	100	77.78
	Fisura 25%	88.89	94.44	100	94.44
	Eficiencia	94.44	77.78	100	90.74
10	Eje sano	100	94.44	100	98.15
	Fisura 12.5 %	94.44	83.33	100	92.59
	Fisura 25%	100	50	100	83.33
	Eficiencia	98.15	75.92	100	91.36
<b>Eficiencia total</b>		<b>98.15</b>	<b>88.19</b>	<b>99.54</b>	<b>95.29</b>

Tabla 6.8: Resultados de clasificación según el eje Y para una red probabilística (s.p.).

La figura 6.17 permite ver que las zonas A y C presentan unas eficiencias de clasificación del 98.15 % y del 99.54 % respectivamente, siendo, por tanto, la zona B la que tiene un peor comportamiento (88.19 %). Además se puede comprobar nuevamente que los valores de clasificación comienzan a descender a partir del nivel de descomposición 7, especialmente para la zona intermedia, ya que para las otras dos zonas apenas se produce un descenso importante en el rendimiento de la red.



En lo referente a la evolución de la eficiencia según los tipos de ejes ensayados mostrada en la figura 6.18, el eje sano sigue siendo el que se consigue clasificar mejor, mientras que el eje con una fisura del 12.5 % presenta un descenso considerable en sus resultados a partir del nivel 7 y el eje con una fisura del 25 % sigue una pauta irregular con altibajos. Por tanto, como sucedía con el anterior caso con el eje Y, los mejores resultados se consiguen con los cuatro primeros niveles de descomposición.

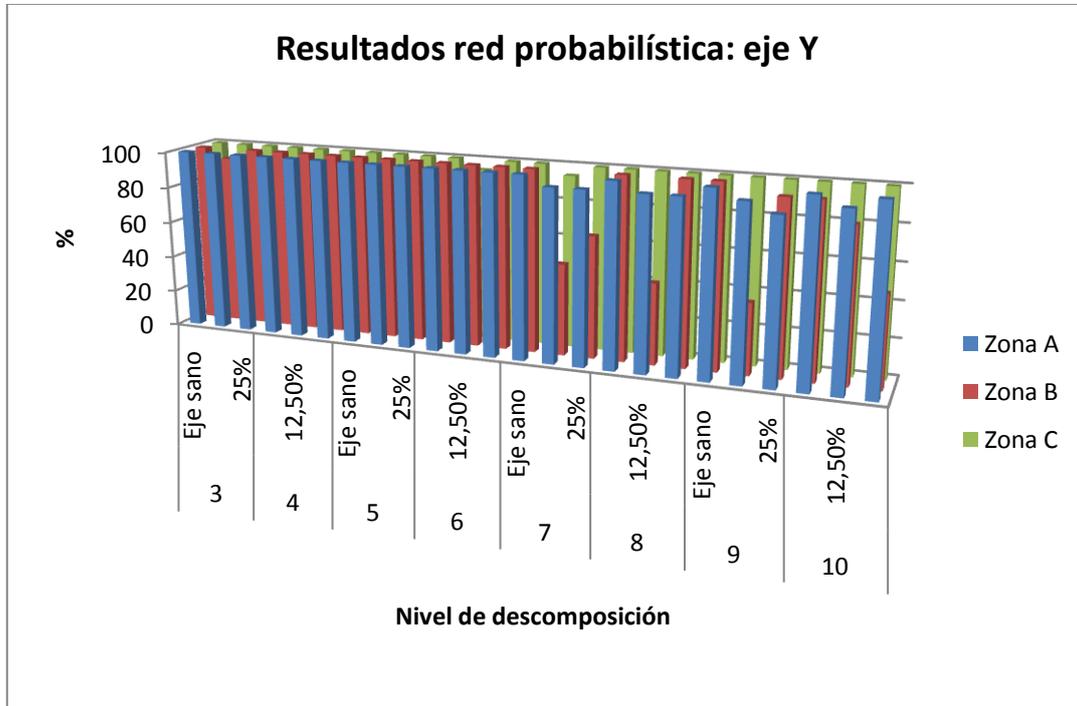


Figura 6.17: Gráfico de clasificación para el eje Y de una red probabilística (s.p.).

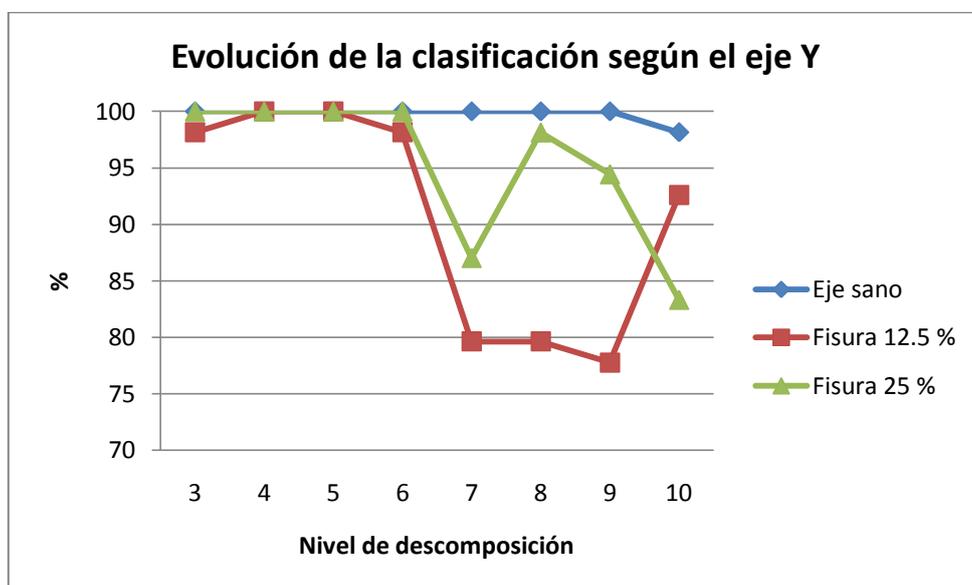


Figura 6.18: Eficiencia de la clasificación según el eje Y de una red probabilística (s.p.).



En la tabla 6.9 se presentan los resultados pertenecientes al eje Z de una red probabilística:

		EJE Z			
Nivel de descomposición		Zona A	Zona B	Zona C	Eficiencia
3	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
4	Eje sano	100	100	100	100
	Fisura 12.5 %	100	77.78	100	92.59
	Fisura 25%	100	100	100	100
	Eficiencia	100	92.59	100	97.53
5	Eje sano	100	100	100	100
	Fisura 12.5 %	100	94.44	100	98.15
	Fisura 25%	100	94.44	100	98.15
	Eficiencia	100	96.29	100	98.76
6	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	88.89	100	96.30
	Eficiencia	100	96.30	100	98.77
7	Eje sano	100	100	100	100
	Fisura 12.5 %	94.44	100	94.44	96.29
	Fisura 25%	100	100	94.44	98.14
	Eficiencia	98.15	100	96.29	98.15
8	Eje sano	100	88.89	100	96.30
	Fisura 12.5 %	100	50	94.44	81.48
	Fisura 25%	88.89	100	88.89	92.59
	Eficiencia	96.30	79.63	94.44	90.12
9	Eje sano	100	77.78	100	92.59
	Fisura 12.5 %	83.33	77.78	66.67	75.93
	Fisura 25%	100	83.33	94.44	92.59
	Eficiencia	94.44	79.63	87.04	87.04
10	Eje sano	100	61.11	100	87.04
	Fisura 12.5 %	83.33	94.44	83.33	87.03
	Fisura 25%	94.44	61.11	94.44	83.33
	Eficiencia	92.59	72.22	92.59	85.80
<b>Eficiencia total</b>		<b>97.68</b>	<b>89.58</b>	<b>96.30</b>	<b>94.52</b>

Tabla 6.9: Resultados de clasificación de una red probabilística según el eje Z (s.p.).

Según la figura 6.19 las zonas donde se obtienen mejores resultados son las zonas A y C, con una eficiencia del 97.68 % para la primera y del 96.30 para la segunda. Además, cabe señalar que, en este caso, estas dos zonas clasifican peor con altos niveles de descomposición, algo que no ocurría en los anteriores estudios. Para la zona intermedia (B) también se consiguen unos porcentajes de clasificación bastante buenos (89.58 %), si bien estos empeoran significativamente con los niveles de descomposición 8, 9 y 10.



En la figura 6.20 aparecen los resultados para cada tipo de eje y nivel de descomposición. Según esta figura, se puede constatar el hecho que acontecía en el párrafo anterior, donde, a partir de un grado de descomposición superior a 6, la eficiencia disminuía, siendo estos niveles los más aconsejables a la hora de obtener mejores resultados. Por otro lado, el eje con una fisura del 12.5 % presenta un comportamiento irregular, mientras que los otros dos siguen unas pautas más estables y previsibles.

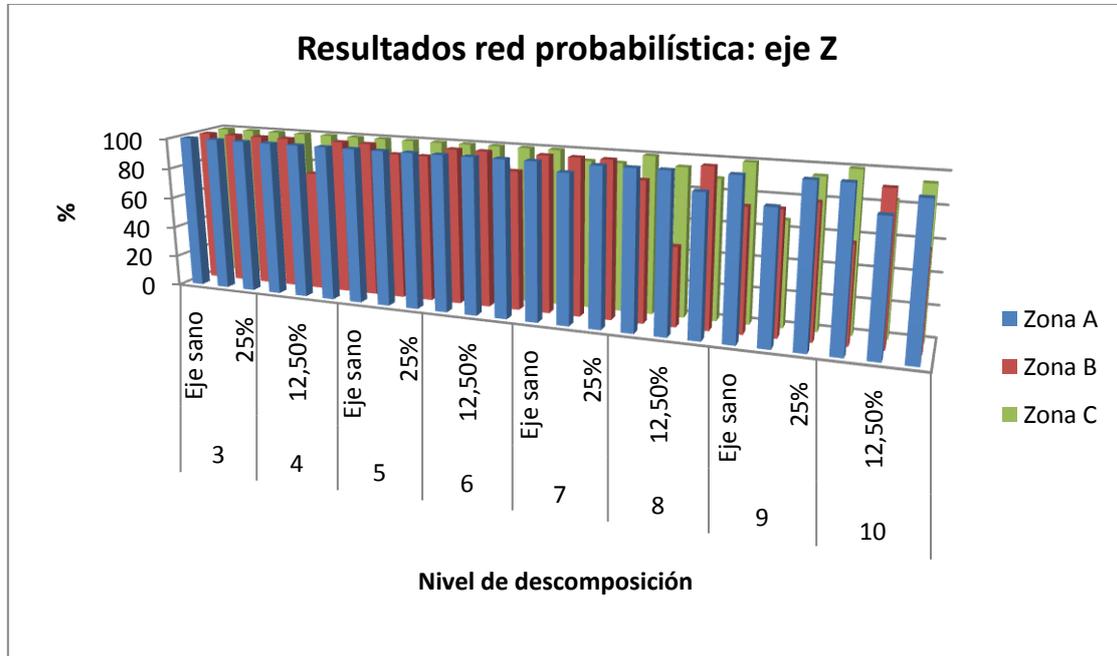


Figura 6.19: Gráfico de clasificación de una red probabilística para el eje Z (s.p.).

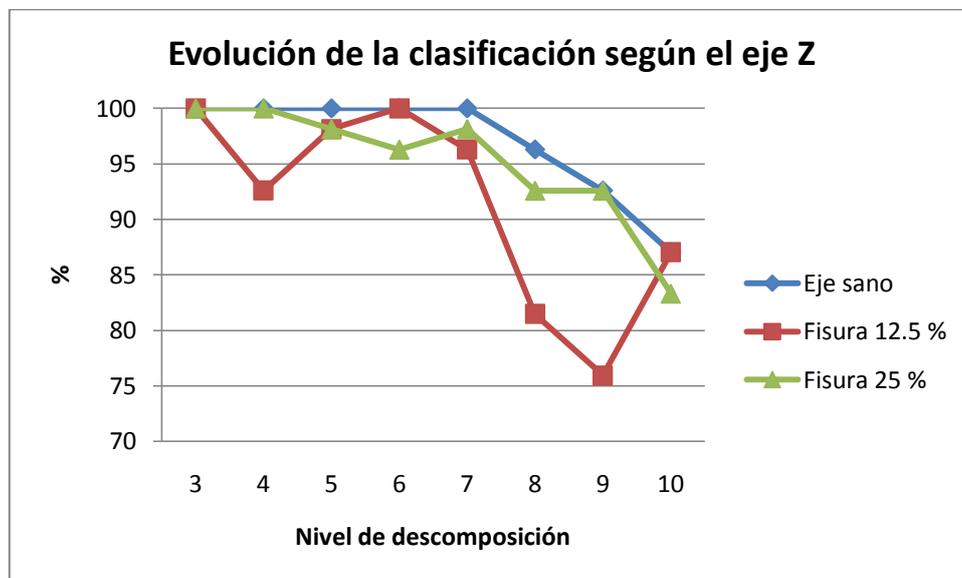


Figura 6.20: Gráfico de clasificación de una red probabilística para el eje Z (s.p.).



Como conclusión parcial a los resultados de este apartado, se puede decir que las zonas A y C son las que obtienen los mejores porcentajes de clasificación, con valores muy cercanos entre ellos y superiores al 95 %, aunque peores que en el caso anterior, donde se incluían los paquetes 1 y 6. Además se observa que, a partir del nivel de descomposición 7, las eficiencias de clasificación para las tres zonas disminuyen considerablemente y, en especial, para la zona B, donde se alcanzan valores próximos al 70 %.

En cuanto al tipo de eje ensayado, se llega a la conclusión de que los cuatro primeros niveles de descomposición son los más adecuados para la clasificación de las señales, obteniéndose buenos resultados en todos los casos. Para los otros cuatro grados de descomposición analizados, el comportamiento es irregular y la única conclusión que se puede obtener es que la eficiencia disminuye en los tres casos de este apartado. También se observa que el eje sano es que consigue unos mejores resultados, mientras que el eje con la fisura del 12.5 % es, nuevamente, el que peores resultados obtiene.

**6.3 RED DE BASE RADIAL**

En este apartado se presentan los resultados de las clasificaciones realizadas con una red de base radial a la que se le han incluido los paquetes 1 y 6. En este caso sólo se incluye la tabla con los porcentajes correspondientes al eje X (tabla 6.10) debido a que son los mismos que los obtenidos para los otros ejes cartesianos Y y Z y para los demás casos en los que no se añaden los paquetes 1 y 6, por lo que no se ha considerado necesario el incluirlos en este capítulo aunque sí se encuentran en los anexos de este proyecto. Tampoco es necesario incluir gráficas en este apartado puesto que los resultados se pueden ver claramente en la tabla y no aportarían ninguna información adicional.

Nivel de descomposición	EJE X				Eficiencia
		Zona A	Zona B	Zona C	
3	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
4	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
5	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
6	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
7	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
8	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
9	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
10	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
Eficiencia total		100	100	100	100

Tabla 6.10: Resultados de clasificación de una red de base radial según el eje X (c.p.).



En este caso, lo único que se puede decir es que la red radial clasifica con gran precisión todas las señales, sea cual sea el eje cartesiano estudiado, el nivel de descomposición o el tipo de eje ensayado en el banco de ensayos, puesto que para cualquier caso se obtiene un porcentaje de clasificación del 100 %.



**6.4 RED DE RECONOCIMIENTO DE PATRONES**

**6.4.1 Red de reconocimiento de patrones incluyendo los paquetes 1 y 6**

En este apartado se muestran los porcentajes de la eficiencia de clasificación de la red de reconocimiento de patrones partiendo de los resultados de los paquetes óptimos que aparecen en las tablas 6.1, 6.2 y 6.3 junto con los paquetes 1 y 6. Las tablas y figuras que aparecen a continuación muestran estos valores de forma ordenada y permiten ver el comportamiento de este tipo de red.

EJE X					
Nivel de descomposición		Zona A	Zona B	Zona C	Eficiencia
3	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
4	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
5	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
6	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
7	Eje sano	94.7	100	100	98.23
	Fisura 12.5 %	100	93.8	100	97.93
	Fisura 25%	94.7	85	100	93.23
	Eficiencia	96.3	92.6	100	96.30
8	Eje sano	90	100	100	96.67
	Fisura 12.5 %	93.8	87.5	100	93.77
	Fisura 25%	94.4	80	100	91.47
	Eficiencia	92.6	88.9	100	93.83
9	Eje sano	100	100	100	100
	Fisura 12.5 %	76.2	80	100	85.40
	Fisura 25%	86.7	88.2	100	91.63
	Eficiencia	87	88.9	100	91.97
10	Eje sano	100	89.5	100	96.50
	Fisura 12.5 %	93.8	87.5	100	93.77
	Fisura 25%	85	84.2	100	89.73
	Eficiencia	92.6	87	100	93.20
Eficiencia total		96.22	94.82	100	97.01

Tabla 6.11: Resultados de clasificación de una red reconocimiento de patrones según el eje X (c.p.).



La figura 6.21 muestra que en la zona C se consigue clasificar perfectamente todas las señales, mientras que para las zonas A y B se logra una eficiencia del 100 % hasta un nivel de descomposición 6, a partir del cual la eficiencia de la red neuronal disminuye pero, no obstante, se siguen obteniendo buenos resultados. Entre estas dos zonas, se puede notar que la zona inicial se comporta algo mejor (96.22 %) que la zona intermedia (94.82 %) aunque no existen grandes diferencias entre ellas.

Respecto a la figura 6.22, cabe decir que el nivel de descomposición a partir del cual comienza a descender la eficiencia de clasificación coincide con el valor obtenido para la figura 6.23. Por otro lado, se sigue teniendo que el eje sano es el que sigue dando los mejores resultados, superiores al 95 %, pero, al contrario de lo ocurría en los casos anteriores, el eje con una fisura del 25 % no se consigue clasificar mejor que el que presenta la fisura del 12.5 % salvo para un grado de descomposición de valor 9.

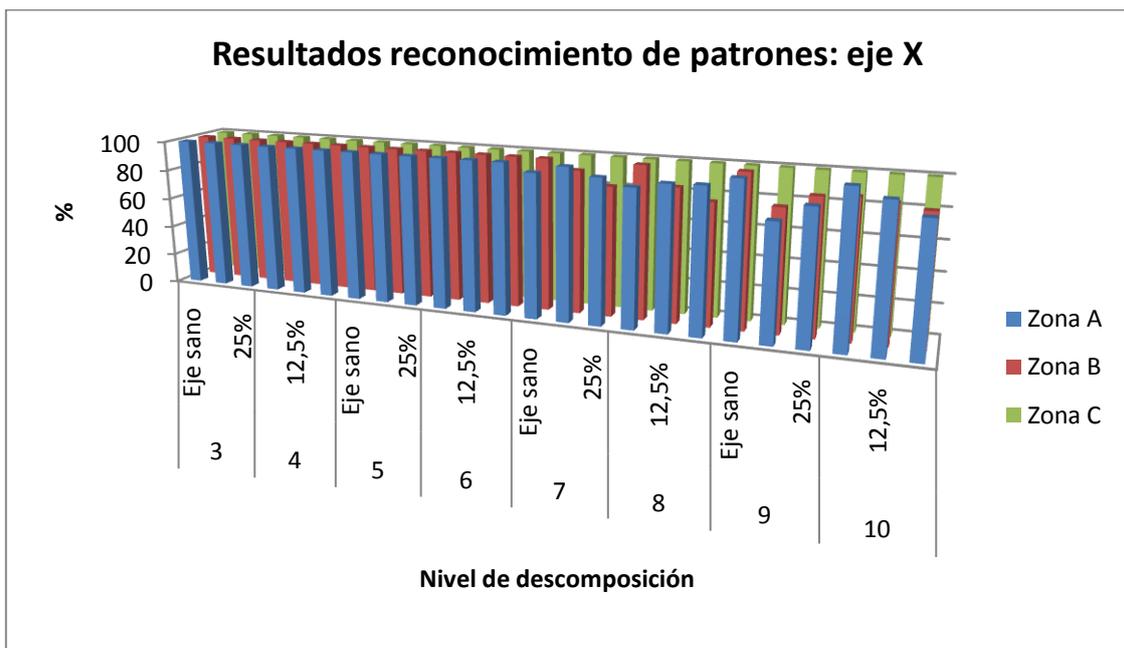


Figura 6.21: Gráfico de clasificación de una red de reconocimiento de patrones según el eje X (c.p.).

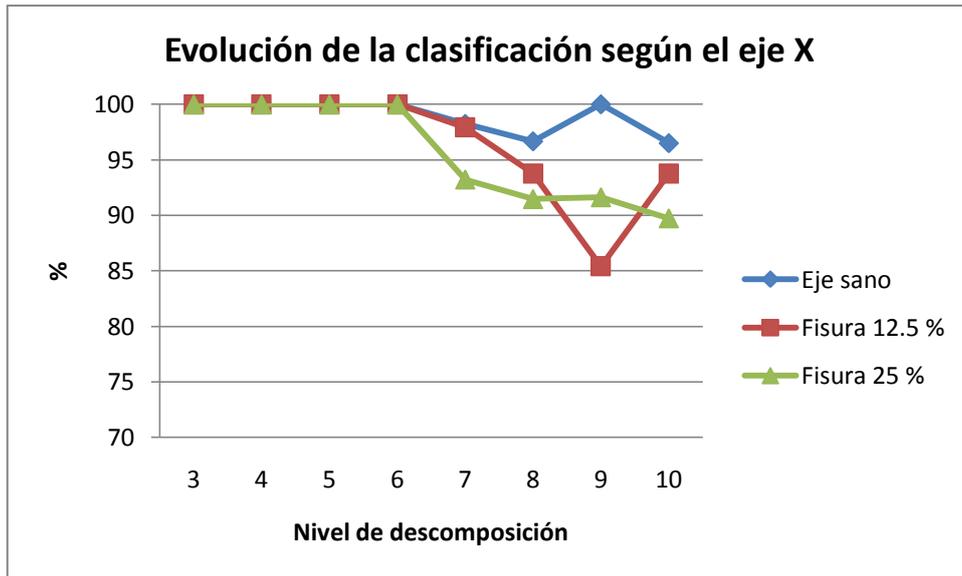


Figura 6.22: Gráfico de la eficiencia de clasificación de una red de reconocimiento de patrones según el eje X (c.p.).



En la tabla 6.12 se muestran los resultados conseguidos por la red de reconocimiento de patrones para el eje Y:

Nivel de descomposición	EJE Y				Eficiencia
		Zona A	Zona B	Zona C	
3	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
4	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
5	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
6	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
7	Eje sano	100	100	100	100
	Fisura 12.5 %	94.7	94.1	100	96.27
	Fisura 25%	100	89.5	100	96.50
	Eficiencia	98.1	94.4	100	97.50
8	Eje sano	94.7	100	100	98.23
	Fisura 12.5 %	94.4	94.4	100	96.27
	Fisura 25%	100	94.4	100	98.13
	Eficiencia	96.3	96.3	100	97.53
9	Eje sano	100	94.7	100	98.23
	Fisura 12.5 %	89.5	100	100	96.50
	Fisura 25%	94.1	90	100	94.70
	Eficiencia	94.4	94.4	100	96.27
10	Eje sano	100	94.7	94.7	96.47
	Fisura 12.5 %	88.2	88.2	100	92.13
	Fisura 25%	84.2	88.9	100	91.03
	Eficiencia	90.7	90.7	98.1	93.17
<b>Eficiencia total</b>		<b>97.49</b>	<b>97.04</b>	<b>99.78</b>	<b>98.10</b>

Tabla 6.12: Resultados de clasificación según el eje Y para una red de reconocimiento de patrones (c.p.).

La zona C, según muestra la figura 6.23, es nuevamente la que mejor se comporta de las tres, obteniendo una eficiencia prácticamente del 100 % (99.78 %). Las otras dos zonas, A y B, también logran unos buenos resultados, 97.49 % y 97.04 % para cada una de ellas respectivamente. Además, se vuelve a cumplir que, para los niveles de descomposición 3, 4, 5 y 6, la red neuronal clasifica las señales perfectamente.



En cuanto a los resultados obtenidos según el tipo de eje, mostrados en la figura 6.24, se tiene que, para este caso, la diferencia no es tan grande como sucedía en otros ejemplos y los tres ejes presentan un comportamiento similar, si bien el eje sano consigue unos porcentajes superiores. También se comprueba que los mejores resultados se logran para los cuatro primeros niveles de descomposición.

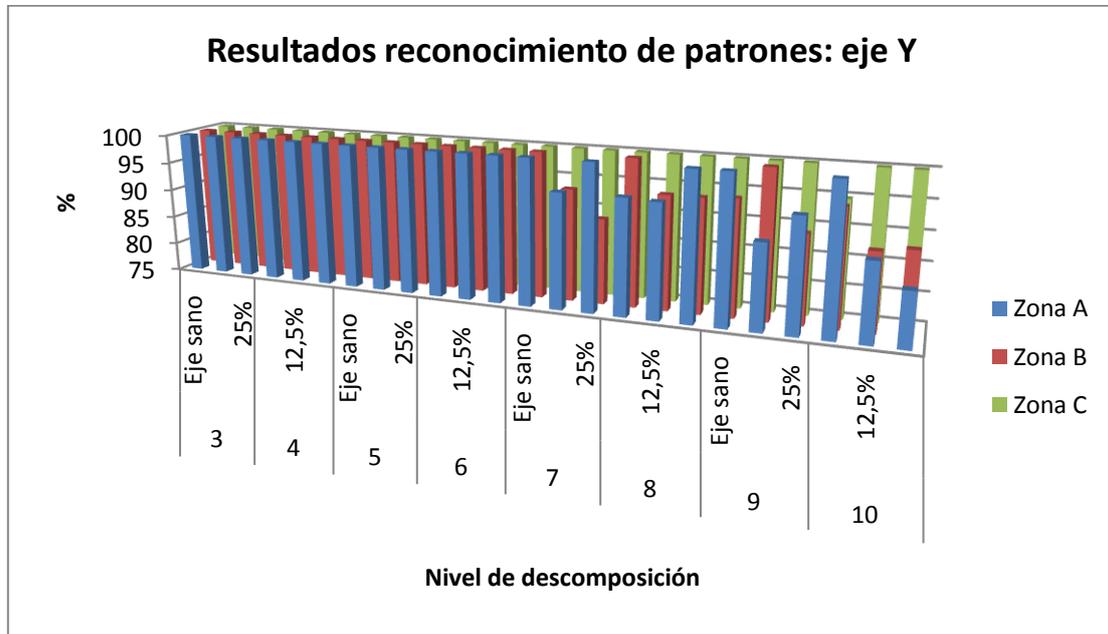


Figura 6.23: Gráfico de clasificación para el eje Y de una red de reconocimiento de patrones (c.p.).

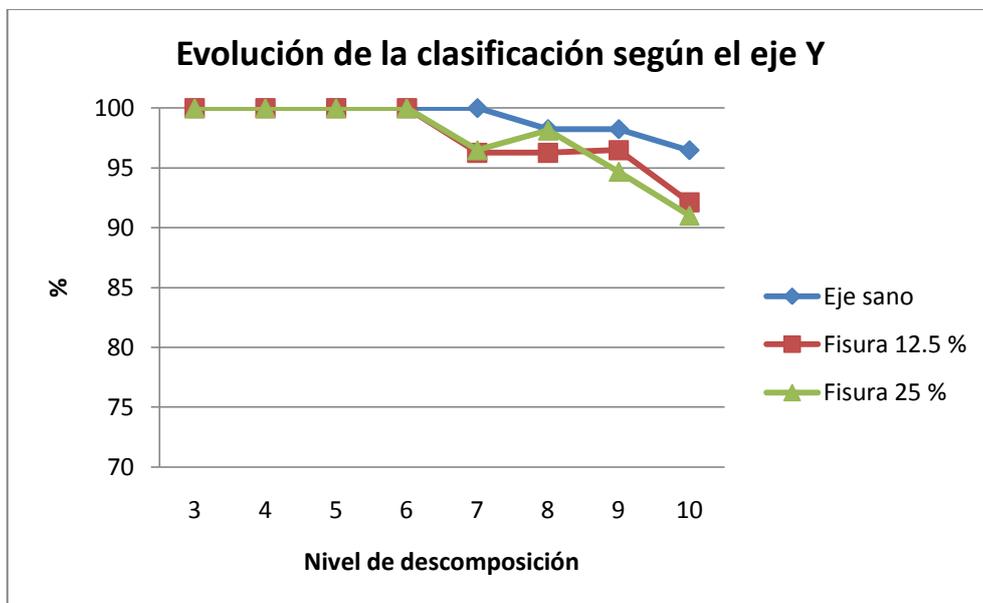


Figura 6.24: Eficiencia de la clasificación según el eje Y de una red de reconocimiento de patrones (c.p.).



A continuación, se presentan en la tabla 6.13 los resultados correspondientes al eje Z para la red de reconocimiento de patrones:

		EJE Z			
Nivel de descomposición		Zona A	Zona B	Zona C	Eficiencia
3	Eje sano	90	100	100	96.67
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	94.7	100	100	98.23
	Eficiencia	94.4	100	100	98.13
4	Eje sano	90	100	100	96.67
	Fisura 12.5 %	93.8	84.2	100	92.67
	Fisura 25%	94.4	88.2	100	94.20
	Eficiencia	92.6	90.7	100	94.43
5	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
6	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
7	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	94.7	98.23
	Eficiencia	100	100	98.1	99.37
8	Eje sano	94.7	90	100	94.90
	Fisura 12.5 %	93.3	93.8	100	95.70
	Fisura 25%	85	94.4	100	93.13
	Eficiencia	90.7	92.6	100	94.43
9	Eje sano	100	73.9	100	91.30
	Fisura 12.5 %	93.8	93.3	100	95.70
	Fisura 25%	85	68.8	100	84.60
	Eficiencia	92.6	77.8	100	90.13
10	Eje sano	100	85.7	100	95.23
	Fisura 12.5 %	77.3	75	90	80.77
	Fisura 25%	92.9	62.5	100	85.13
	Eficiencia	88.9	72.2	96.3	85.80
<b>Eficiencia total</b>		<b>95.20</b>	<b>92.08</b>	<b>99.36</b>	<b>95.55</b>

Tabla 6.13: Resultados de clasificación de una red reconocimiento de patrones para el eje Z (c.p.).

Como se puede ver en la figura 6.25, la zona que tiene una mayor eficiencia en la clasificación de las señales es, como ha venido ocurriendo hasta ahora, la zona C, con un valor de 99.36 %. Después de esta zona, se observa que la primera zona de estudio es la siguiente que clasifica mejor (95.20 %), mientras que para la zona B se alcanza un valor del 92.08 %. Además se puede comprobar que los niveles de descomposición para los que las tres franjas



clasifican sin ningún error son los niveles 5, 6 y 7, entretanto que los niveles 3 y 4 no logran los resultados conseguidos en los otros casos anteriores, aunque su eficiencia es bastante alta.

Respecto a la clasificación según el tipo de eje mostrada en la figura 6.26, se observa que las eficiencias de los tres ejes evolucionan de forma bastante pareja hasta un grado de descomposición de 9, donde las diferencias entre ellos aumentan. Cabe destacar la caída brusca de la eficiencia del eje con una fisura del 12.5 % para el último nivel estudiado. Finalmente, se aprecia que sólo se consigue clasificar el 100 % de las señales de los tres ejes en los niveles 5 y 6.

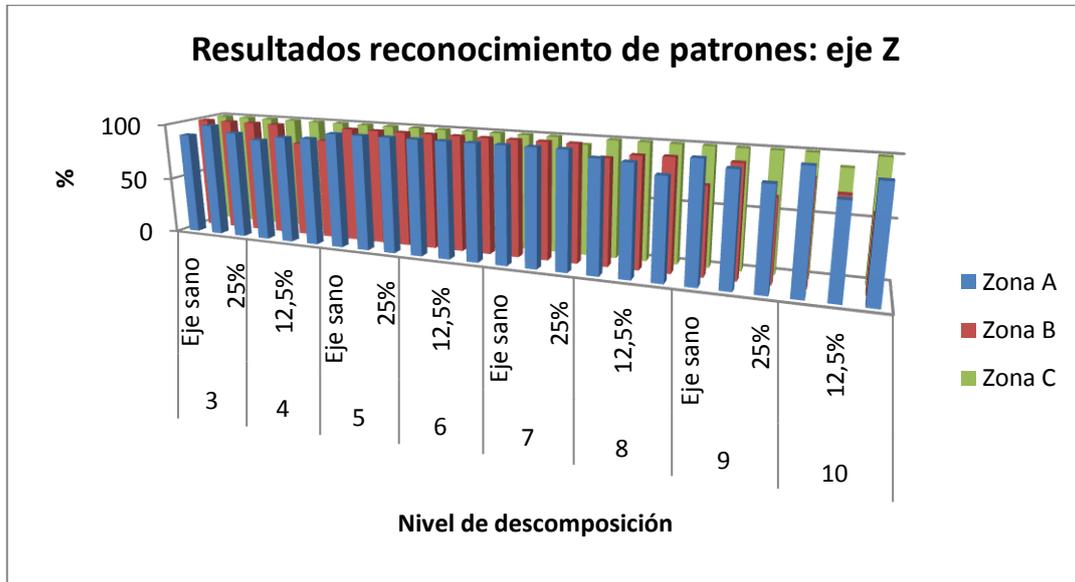


Figura 6.25: Gráfico de clasificación de una red de reconocimiento de patrones para el eje Z (c.p.).

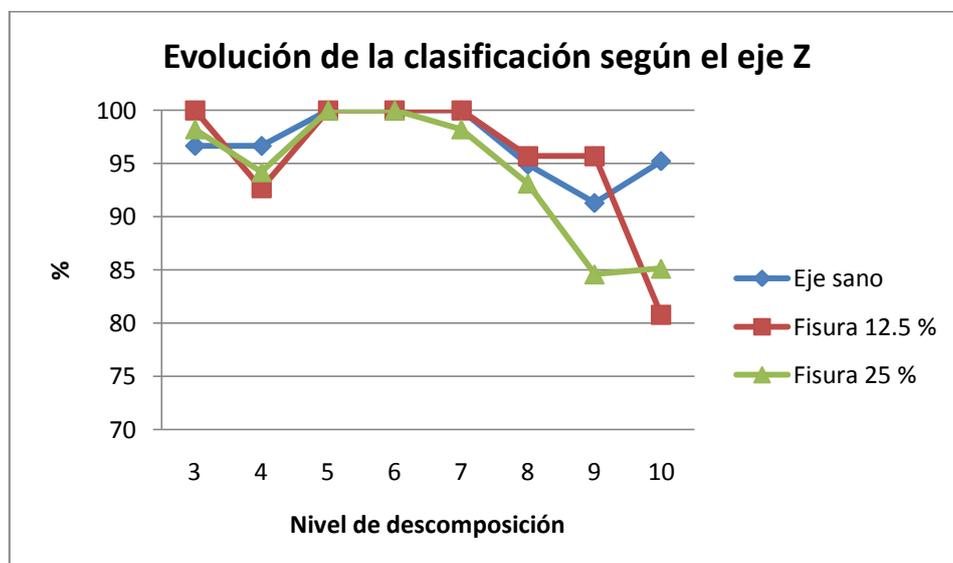


Figura 6.26: Evolución de la clasificación del eje Z para una red de reconocimiento de patrones (c.p.).



Según los resultados obtenidos para los tres ejes cartesianos, se puede decir que la zona C es la que consigue los porcentajes más altos, superiores en todos los casos al 99 %. Las otras dos zonas presentan comportamientos similares, aunque la zona B sigue obteniendo los peores resultados pero cercanos a los de la zona A. Además, se puede apreciar que salvo en este último caso, correspondiente al eje Z, los resultados de la clasificación para las tres zonas estudiadas y los cuatro primeros niveles de descomposición son del 100 %. Estos niveles comentados son, de nuevo, los más recomendables para la clasificación con las redes neuronales.

Respecto a los ejes ensayados, se aprecian bastantes diferencias en los resultados según el eje cartesiano estudiado, siendo el eje sano el que presenta un comportamiento más regular, mientras que los otros dos ejes con fisuras siguen una pauta irregular. En cuanto a los niveles de descomposición, cabe decir que, para los niveles 5 y 6 la eficiencia alcanzada en todos los casos es del 100 %.



**6.4.2 Red de reconocimiento de patrones excluyendo los paquetes 1 y 6**

A continuación se presentan los resultados de los porcentajes de clasificación de una red de reconocimiento de patrones a partir de los paquetes óptimos de las tablas 6.1, 6.2 y 6.3 exceptuando la inclusión de los paquetes 1 y 6. Los resultados obtenidos se incluyen en las tablas que aparecen a continuación, así como también se adjuntan los gráficos correspondientes a estos resultados.

Nivel de descomposición	EJE X				Eficiencia
		Zona A	Zona B	Zona C	
3	Eje sano	100	100	100	100
	Fisura 12.5 %	100	66.7	100	88.90
	Fisura 25%	100	61.9	100	87.30
	Eficiencia	100	75.9	100	91.97
4	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
5	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
6	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
7	Eje sano	100	100	100	100
	Fisura 12.5 %	94.7	90	100	94.90
	Fisura 25%	100	100	100	100
	Eficiencia	98.1	96.3	100	98.13
8	Eje sano	100	90	100	96.67
	Fisura 12.5 %	100	82.4	100	94.13
	Fisura 25%	94.7	88.2	100	94.30
	Eficiencia	98.1	87	100	95.03
9	Eje sano	100	94.1	100	98.03
	Fisura 12.5 %	76.2	70	100	82.07
	Fisura 25%	86.7	82.4	100	89.70
	Eficiencia	87	81.5	100	89.50
10	Eje sano	100	77.3	100	92.43
	Fisura 12.5 %	81	91.7	100	90.90
	Fisura 25%	93.3	80	100	91.10
	Eficiencia	90.7	81.5	100	90.73
<b>Eficiencia total</b>		<b>96.94</b>	<b>90.61</b>	<b>100</b>	<b>95.85</b>

Tabla 6.14: Resultados de clasificación de una red de reconocimiento de patrones según el eje X (s.p.).



La figura 6.27 muestra que todas las señales correspondientes a la zona C se consiguen clasificar perfectamente para todos los niveles de descomposición. Por otro lado, la zona A también consigue clasificar muy bien, con una eficiencia del 96.94 %, disminuyendo considerablemente para las tres últimas descomposiciones realizadas. Algo parecido ocurre con la zona B, que se comporta de forma similar excepto para el grado 3, donde la eficiencia es baja y también consigue unos resultados peores que la zona anterior (90.61 %).

En la figura 6.28 se puede observar que el eje sano es el que se consigue clasificar mejor de los tres, seguido del eje con una fisura del 25 %, a diferencia de los casos anteriores donde era el eje con la fisura del 12.5 % el que presentaba un mejor rendimiento. Además, para los niveles de descomposición comprendidos entre el 4 y el 8, ambos inclusive, se logran unas eficiencias bastante elevadas para todos los ejes, cercanas al 95 % o superiores, siendo los niveles 4, 5 y 6 donde se alcanzan resultados del 100 %. Sin embargo, para las descomposiciones 3, 9 y 10, los porcentajes obtenidos son bastante peores en comparación con el resto.

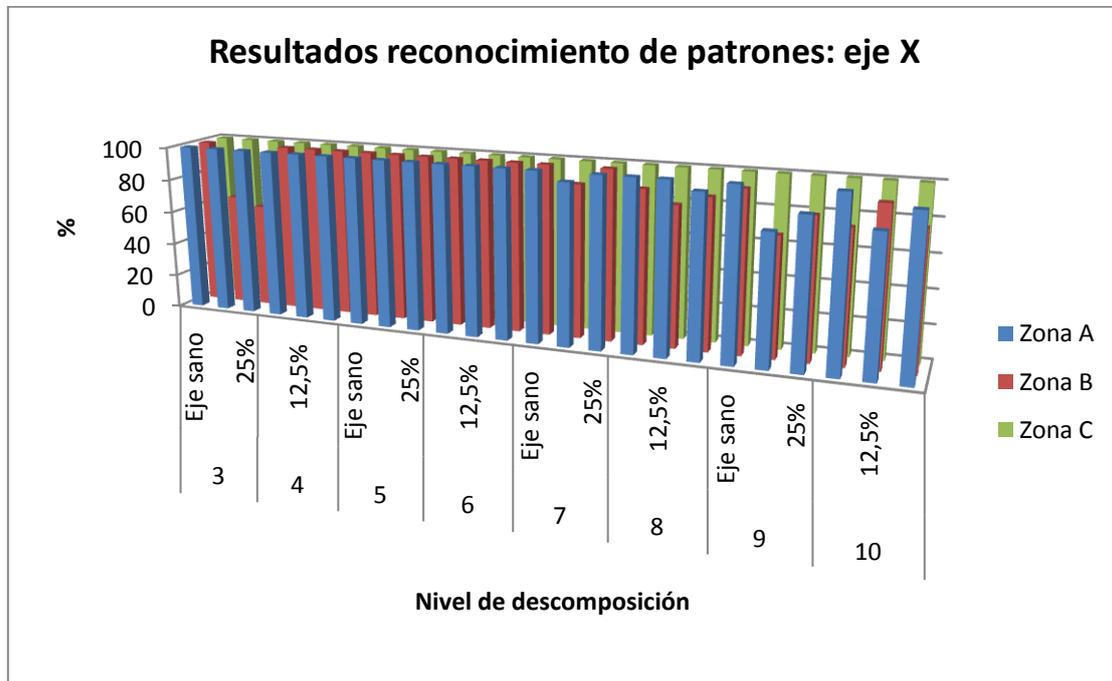


Figura 6.27: Gráfico de clasificación para el eje X de una red de reconocimiento de patrones (s.p.).

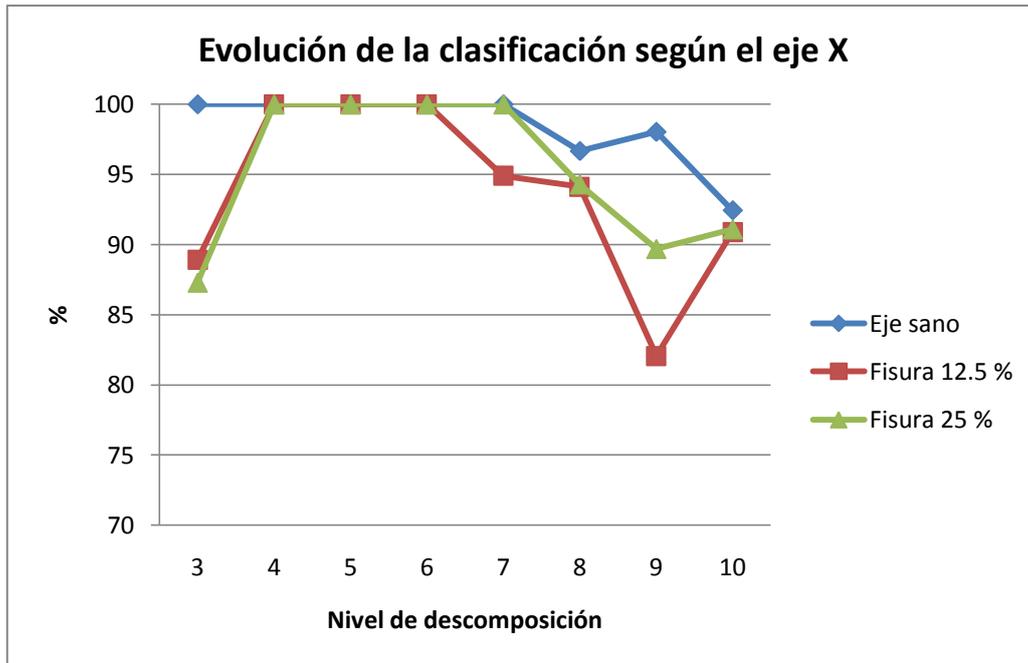


Figura 6.28: Gráfico de clasificación de una red de reconocimiento de patrones para el eje X (s.p.).



En la tabla 6.15 se presentan los porcentajes de clasificación de la red de reconocimiento de patrones para el eje Y:

		EJE Y			
Nivel de descomposición		Zona A	Zona B	Zona C	Eficiencia
3	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
4	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
5	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
6	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
7	Eje sano	100	94.7	100	98.23
	Fisura 12.5 %	85.7	71.4	100	85.70
	Fisura 25%	100	85.7	100	95.23
	Eficiencia	94.4	83.3	100	92.57
8	Eje sano	100	85.7	90	91.90
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	94.7	90	100	94.90
	Eficiencia	98.1	90.7	96.3	95.03
9	Eje sano	100	96.3	85.7	94
	Fisura 12.5 %	84.2	94.7	100	92.97
	Fisura 25%	88.2	100	100	96.07
	Eficiencia	90.7	94.7	94.4	93.27
10	Eje sano	100	100	85.7	95.23
	Fisura 12.5 %	88.2	88.9	100	92.37
	Fisura 25%	84.2	88.9	100	91.03
	Eficiencia	90.7	92.6	94.4	92.57
<b>Eficiencia total</b>		<b>96.88</b>	<b>95.68</b>	<b>98.39</b>	<b>96.98</b>

Tabla 6.15: Resultados de clasificación según el eje Y para una red de reconocimiento de patrones (s.p.).

En este caso, tal y como se observa en la figura 6.29, el comportamiento de las tres zonas es bastante similar, obteniéndose eficiencias del 96.88 %, 95.68 % y 98.39 % para las zonas A, B y C respectivamente. También puede verse que los resultados empeoran con el nivel de descomposición 7 o los superiores, aunque las eficiencias logradas son bastante altas por norma general.



En cuanto a los resultados mostrados por la figura 6.30, se tiene que para las cuatro primeras descomposiciones la eficiencia alcanzada para los tres ejes es del 100 %, mientras que para el resto, los valores conseguidos son peores. Además, el eje con la fisura del 25 % es el que presenta un comportamiento más regular y una eficiencia parecida al del eje sano, que hasta ahora es el que siempre se ha obtenido los mejores resultados con diferencia. Por el contrario, el eje con la fisura del 12.5 % presenta un comportamiento más variable.

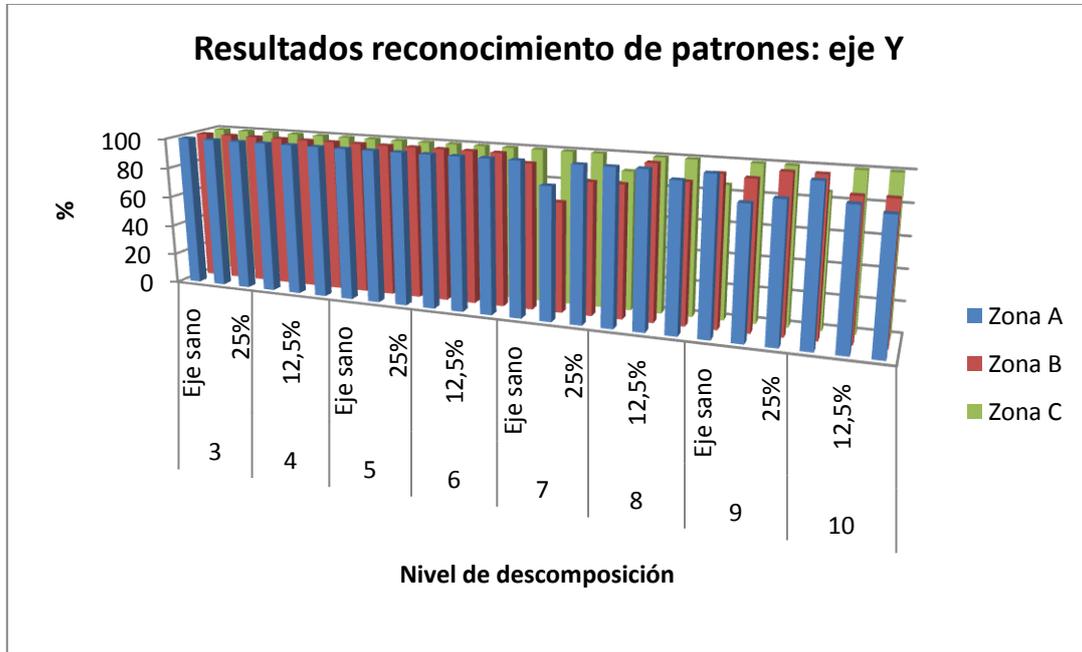


Figura 6.29: Gráfico de clasificación de una red de reconocimiento de patrones según el eje Y (s.p.).

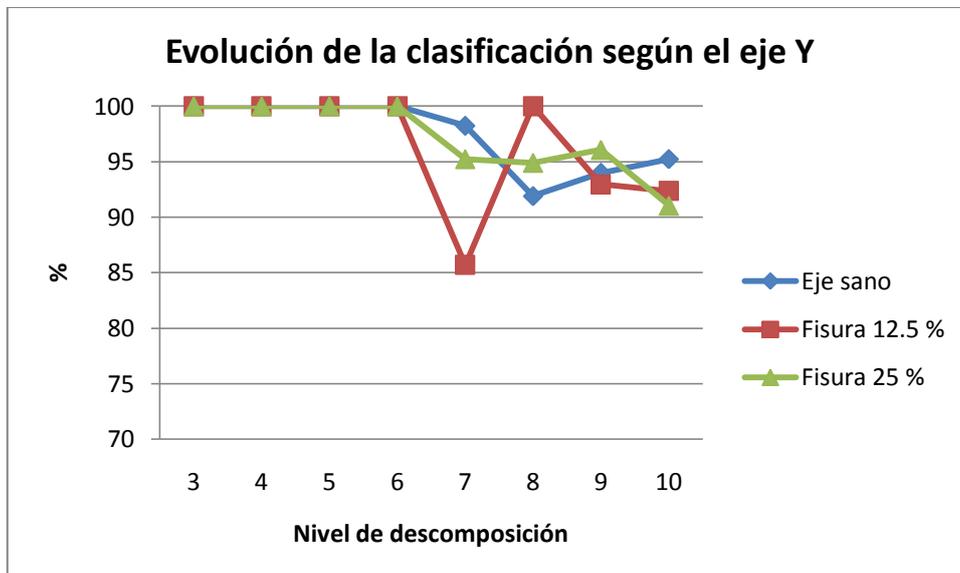


Figura 6.30: Gráfico de la eficiencia de clasificación según el eje Y para una red de reconocimiento de patrones (s.p.).



Los resultados de red de reconocimiento de patrones pertenecientes al eje Z se resumen en la tabla 6.16:

EJE Z					
Nivel de descomposición		Zona A	Zona B	Zona C	Eficiencia
3	Eje sano	94.7	100	100	98.23
	Fisura 12.5 %	89.5	100	100	96.50
	Fisura 25%	100	100	100	100
	Eficiencia	94.4	100	100	98.13
4	Eje sano	85.7	100	100	95.23
	Fisura 12.5 %	100	89.5	100	96.50
	Fisura 25%	94.7	94.1	100	96.27
	Eficiencia	92.6	94.4	100	95.67
5	Eje sano	100	100	100	100
	Fisura 12.5 %	94.7	100	100	98.23
	Fisura 25%	100	100	100	100
	Eficiencia	98.1	100	100	99.37
6	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	94.7	100	98.23
	Eficiencia	100	98.1	100	99.37
7	Eje sano	100	100	100	100
	Fisura 12.5 %	100	94.4	94.7	96.37
	Fisura 25%	90	94.7	100	94.90
	Eficiencia	96.3	96.3	98.1	96.90
8	Eje sano	100	88.9	100	96.30
	Fisura 12.5 %	77.3	88.2	89.5	85
	Fisura 25%	92.9	94.7	94.1	93.90
	Eficiencia	88.9	90.7	94.4	91.33
9	Eje sano	94.7	81.3	100	92
	Fisura 12.5 %	78.9	76.5	78.6	78
	Fisura 25%	87.5	61.9	68.2	72.53
	Eficiencia	87	72.2	81.5	80.23
10	Eje sano	94.7	81.3	94.7	90.23
	Fisura 12.5 %	75	63.6	93.3	77.3
	Fisura 25%	65.2	68.8	85	73
	Eficiencia	77.8	70.4	90.7	79.63
<b>Eficiencia total</b>		<b>92.31</b>	<b>90.53</b>	<b>95.75</b>	<b>92.86</b>

Tabla 6.16: Resultados de clasificación de una red de reconocimiento de patrones para el eje Z (s.p.).

La figura 6.31 muestra que de nuevo la zona donde se alcanza una mayor eficiencia es la zona C (95.75 %), seguida de la zona A (92.31 %) y de la zona B (90.53 %). También se puede notar que los porcentajes de clasificación disminuyen considerablemente con los niveles de descomposición 8, 9 y 10, especialmente en estos dos últimos, donde en algunos casos la eficiencia lograda ronda el 70 %. Además, se observa que no existe ningún nivel de



descomposición donde se consiga una eficiencia del 100 % para las tres zonas, tal y como ocurría en casos anteriores, aunque los mejores resultados se producen para los niveles 5 y 6.

Respecto al comportamiento de la red según el tipo de eje ensayado que muestra la figura 6.32, se tiene que, hasta el nivel de descomposición 7, los resultados alcanzados superan el 95 % de eficiencia, mientras que, a partir de este nivel, los porcentajes conseguidos empeoran bastante, sobre todo para los ejes con fisuras. Nuevamente, el eje sano es el que obtiene los mejores resultados y, como ocurría en el párrafo anterior, no existe ninguna zona para la cual se logre la clasificación del 100 % en los tres ejes simultáneamente.

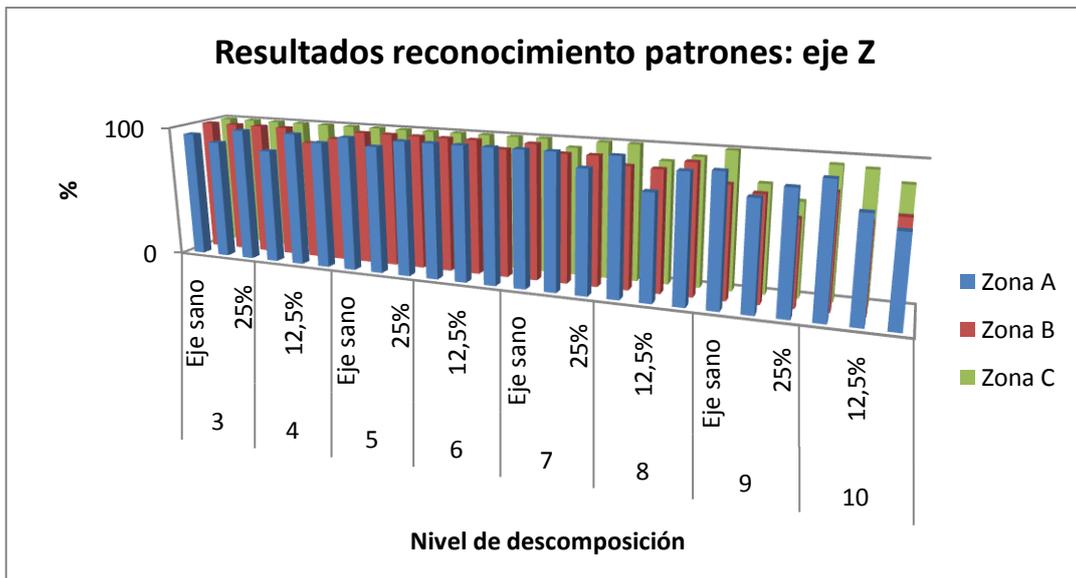


Figura 6.31: Gráfico de clasificación de una red de reconocimiento de patrones para el eje Z (s.p.).

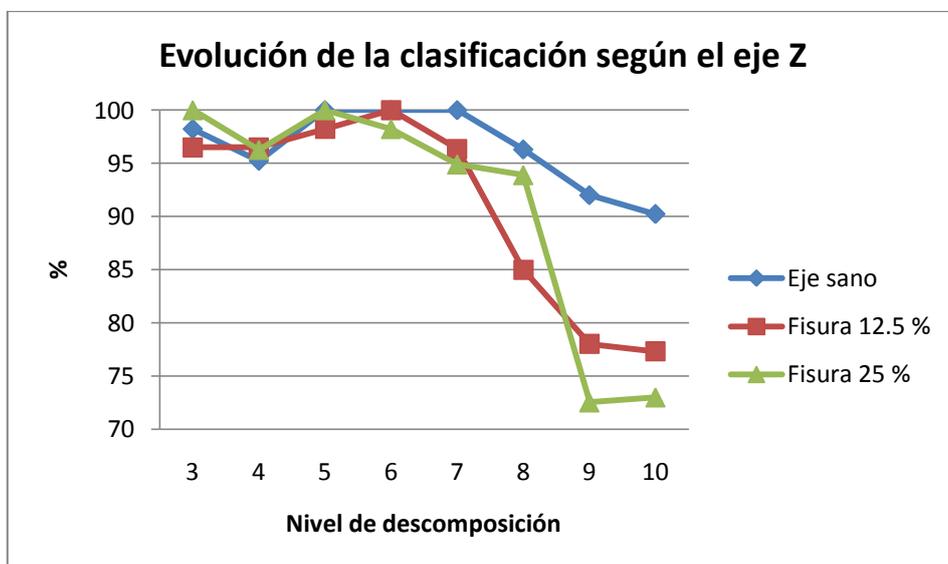


Figura 6.32: Evolución de la clasificación del eje Z para una red de reconocimiento de patrones (s.p.).



Según los resultados de este apartado, se tiene nuevamente que la zona C es la que logra una mayor eficiencia, aunque los resultados en los casos del eje Y y Z son bastante parejos. También se aprecia que los porcentajes alcanzados son bastante peores cuando se emplean niveles de descomposición elevados (8, 9 y 10).

Respecto al comportamiento según el tipo de eje ensayado, se puede decir que el comportamiento para todos los casos es bastante irregular y, en especial, para los cuatro últimos niveles de descomposición. Para los otros niveles, los resultados alcanzados son elevados, superiores al 95 % salvo en caso del eje X donde, para un nivel de descomposición de 3, la eficiencia obtenida para los ejes con fisura disminuye considerablemente. También se puede apreciar que no hay ningún nivel de descomposición en el que se alcancen resultados del 100 % para los tres ejes ensayados y los tres cartesianos.

## 6.5 PRESUPUESTO

En este apartado se presenta un presupuesto con los costes del proyecto. En las tablas 6.17, 6.18 y 6.19 se detallarán los costes de todos los elementos empleados durante el desarrollo de este proyecto, así como los costes de personal y las horas empleadas en la realización de este trabajo. Dicho proyecto ha tenido una duración de **11** meses y se ha considerado una tasa de costes indirectos del **20 %**.

Descripción	Coste (€)	% uso dedicado proyecto	Dedicación (meses)	Período de depreciación	Coste imputable <sup>4</sup>
Ordenador	737.18	100	10	60	<b>122.86</b>
Máquina Rotokit <sup>5</sup>	3.734,25	100	2	60	<b>124.48</b>
Acelerómetro MMF KS943B.10	880	100	2	60	<b>29.33</b>
Filtros MMF M32	280	100	2	60	<b>9.33</b>
Tarjeta de adquisición Keithley KUSB-3100	260.63	100	2	60	<b>8.69</b>
Programa TestPoint™	970.16	100	2	60	<b>32.34</b>
Programa MATLAB® <sup>6</sup>	700	100	6	60	<b>70</b>
Microsoft Office®	0	100	9	60	<b>0</b>

Tabla 6.17: Desglose presupuestario (equipos).

<sup>4</sup> Fórmula de cálculo de la amortización:

$$\frac{A}{B} \times C \times D$$

A = nº de meses desde la fecha de facturación en que el equipo es utilizado.

B = período de depreciación (60 meses).

C = coste del equipo (sin IVA).

D = % del uso que se dedica al proyecto.

<sup>5</sup> En este apartado se incluyen todos los elementos necesarios para el desarrollo de los ensayos.

<sup>6</sup> El precio de la licencia del programa MATLAB® incluye la aplicación Neural Network Toolbox y varía en función de conceptos tales como el tipo de licencia adquirida, el número de usuarios o las aplicaciones añadidas.



Categoría	Dedicación (hombres mes)	Coste hombre mes <sup>7</sup>	Coste (€)
Ingeniero Senior	0,2	4.289,54	857,91
Ingeniero	2	2.694,39	5.388,78
Hombre mes	2,2	<b>Total</b>	<b>6.246,69</b>

Tabla 6.18: desglose presupuestario (personal).

Presupuesto Costes Totales	Presupuesto Costes Totales (€)
Personal	6.247
Amortización	397
Subcontratación de tareas	0
Costes de funcionamiento	0
Costes indirectos	1.329
<b>Total</b>	<b>7.972</b>

Tabla 6.19: Resumen de costes.

El coste final del proyecto desarrollado por el departamento de Ingeniería Mecánica de la Universidad Carlos III de Madrid asciende a un valor total de **7.972** euros.

---

<sup>7</sup> 1 Hombre mes = 131,25 horas.



## **Capítulo 7:**

### Conclusiones y propuestas de mejora



## **7. CONCLUSIONES Y MEJORAS**

En este séptimo capítulo, se presentan las conclusiones obtenidas a partir de los resultados presentados en el capítulo 6 así como una serie de propuestas de mejora y posibles desarrollos futuros relativos a este proyecto con el objetivo de mejorar y aplicar los conocimientos adquiridos en el campo de las redes neuronales para acercarlos a su aplicación en sistemas de monitorización de procesos industriales.

### **7.1 CONCLUSIONES**

En las siguientes líneas se presentan las principales conclusiones que se pueden deducir a partir de los resultados obtenidos y mostrados en el capítulo 6:

- Una primera conclusión a la que se puede llegar es que apenas existen diferencias entre los resultados conseguidos para cada uno de los ejes cartesianos, tal y como muestra la tabla 7.1. Esto indica que no es necesario medir en los tres ejes simultáneamente y que podría valer con cualquier eje, si bien el eje Y es el que presenta una mayor eficiencia, aunque la diferencia respecto al eje Z, que es el que tiene un peor porcentaje de clasificación, no llega a un 1.5 %.

Eje	Eficiencia total (%)
X	97.56
Y	97.73
Z	96.35

Tabla 7.1: Resultados de la eficiencia de clasificación por eje.

- El hecho de que no sea necesario medir en los tres ejes cartesianos implica una consecuencia importante que consiste en la reducción del número de cables requeridos, algo que, aunque en la configuración empleada para este proyecto no supone un cableado extenso, en instalaciones industriales con varios sensores dentro de una misma máquina puede suponer algún problema. También conllevaría el uso de acelerómetros más sencillos, como son los uniaxiales, en lugar de los acelerómetros triaxiales como el empleado en el Rotokit, así como una mayor rapidez en el procesamiento de los datos adquiridos.
- La siguiente conclusión que se puede inferir de la tabla 7.2 es que los niveles de descomposición wavelet más idóneos para la clasificación de las señales son los niveles 4, 5 y 6, especialmente los dos últimos, con valores cercanos al 100 %, aunque los tres superan el 99 % de eficiencia. También se observa que el aumentar el grado de descomposición no implica unos resultados mejores sino al revés, éstos van empeorando conforme aumenta el nivel de descomposición a partir del nivel 5, obteniéndose la eficiencia más baja para el grado 10.



Nivel de descomposición	Eficiencia total (%)
3	98.63
4	99.28
5	99.90
6	99.83
7	97.22
8	95.81
9	93.52
10	93.00

Tabla 7.2: Resultados de la eficiencia de clasificación según el nivel de descomposición.

- Como se deduce de la tabla 7.3, la zona del ensayo donde se obtienen los mejores resultados es la denominada zona C, que se corresponde con la parte del ensayo referente al régimen estacionario. Este hecho choca en cierta medida con la idea inicial de que las zonas de arranque iban a ser las que proporcionasen mejores resultados, pero si vemos los resultados conseguidos, estas dos zonas del régimen transitorio y, especialmente la primera, también presentan una elevada eficiencia.

Zona	Eficiencia total (%)
A	97.91
B	94.54
C	99.19

Tabla 7.3: Resultados según la zona estudiada.

- Una consecuencia de que la zona que consiga mejores resultados sea la correspondiente al régimen de velocidad constante es que conlleva una mayor facilidad en la aplicación a sistemas de monitorización de procesos, puesto que no es necesario realizar ciclos de arranque-parada para identificar la presencia de fisuras, siendo necesario medir únicamente en régimen permanente.
- Otra conclusión muy importante es conocer cuál es la red neuronal que mejor se comporta para los ensayos realizados. Como ya se pudo ver en el capítulo anterior, la red de tipo radial consigue clasificar todas las señales de entrada, siendo la más idónea para la clasificación de los datos de este proyecto. Respecto a las otras dos redes empleadas, apenas existe una gran diferencia entre el uso de una red probabilística o el de una red de reconocimiento de patrones como la del programa MATLAB®, si bien esta última consigue una eficiencia algo mayor, como muestra la tabla 7.4.



Tipo de red neuronal	Eficiencia total (%)
Radial	100
Probabilística	95.58
Reconocimiento de patrones	96.06

Tabla 7.4: Eficiencia de clasificación por tipo de red.

- De la tabla 7.5 y de la figura 7.1 se obtiene que los resultados de las redes a las que se les añaden los paquetes 1 y 6 son mejores según el nivel de descomposición empleado, por regla general, que aquellas que únicamente emplean los paquetes óptimos de las tablas 6.1, 6.2 y 6.3 del capítulo anterior. Estas diferencias en la eficiencias alcanzadas son pequeñas o nulas para las redes probabilística y radial respectivamente y algo mayores para la red de reconocimiento de patrones, aunque en todos los casos la eficiencia es bastante alta.
- En cuanto a la eficiencia global de las redes neuronales mostrada en la tabla 7.5, se observa que todas ellas clasifican las señales muy bien, pero hay un hecho que llama la atención y es que, la red de reconocimiento de patrones con los paquetes 1 y 6 incluidos consigue un mejor resultado que la red probabilística en las mismas condiciones, como ocurría en la tabla 7.4, pero cuando no se incluyen dichos paquetes, es esta última red la que logra una mayor eficiencia.

Nivel de descomposición	Radial con paquetes 1 y 6	Radial sin paquetes 1 y 6	Probabilística con paquetes 1 y 6	Probabilística sin paquetes 1 y 6	Reconocimiento de patrones con paquetes 1 y 6	Reconocimiento de patrones sin paquetes 1 y 6
3	100	100	96.91	98.77	99.38	96.7
4	100	100	99.79	99.18	98.14	98.56
5	100	100	100	99.59	100	99.79
6	100	100	99.79	99.38	100	99.79
7	100	100	95.47	94.24	97.72	95.87
8	100	100	93.21	92.59	95.27	93.8
9	100	100	90.33	90.33	92.79	87.67
10	100	100	89.92	89.71	90.72	87.64
<b>Eficiencia</b>	<b>100</b>	<b>100</b>	<b>95.68</b>	<b>95.47</b>	<b>96.75</b>	<b>94.98</b>

Tabla 7.5: Resultados según el nivel de descomposición y red empleada.

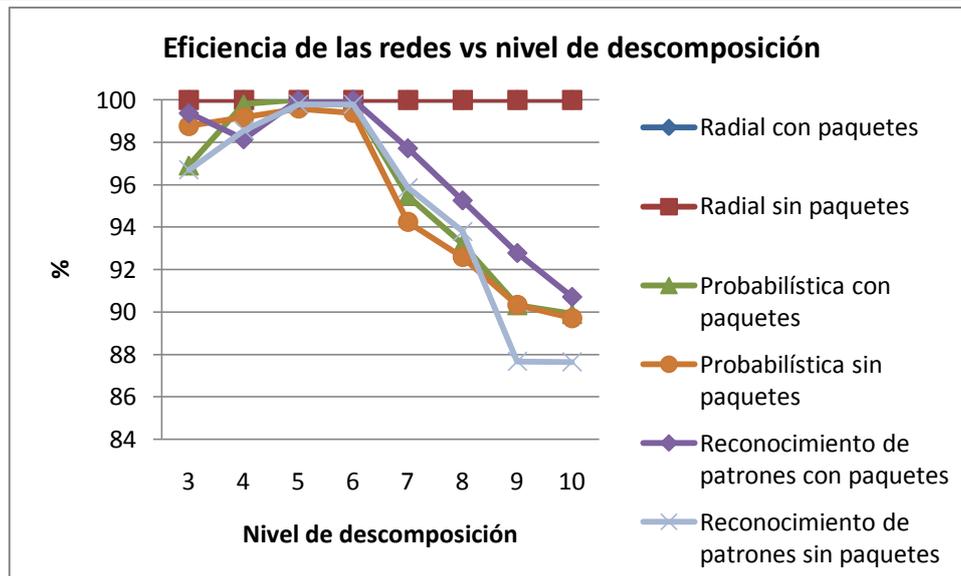


Figura 7.1: Eficiencia según el nivel de descomposición y tipo de red.

## **7.2 PROPUESTAS DE MEJORA**

A continuación se presentan una serie de propuestas de mejora y futuros desarrollos relacionados con este proyecto y que se podrían llevar a cabo en trabajos posteriores:

- Realizar fisuras intermedias a las analizadas con el objetivo de comprobar si las redes neuronales empleadas en este proyecto se muestran igual de eficaces o bien varía su comportamiento al haber un menor salto entre los tamaños de cada fisura.
- Analizar fisuras mayores, como puede ser otro eje con una fisura del 50 % y que, aunque estaba previsto su empleo en este proyecto, finalmente ha tenido que ser descartado por motivos de seguridad, ya que sufría oscilaciones de gran importancia a escasas revoluciones que podían provocar la rotura del eje. Por este motivo, para estudiar este caso habría que buscar una configuración menos crítica con este caso, si bien es posible que sea más difícil la clasificación de los otros casos.
- Probar con otro tipo de fisuras que no sean perpendiculares al eje sino que sean oblicuas al mismo.
- Intentar comparar los resultados obtenidos en este proyecto con los conseguidos mediante un acelerómetro uniaxial.
- Realizar los mismos ensayos pero modificando la disposición de los discos en el eje, como puede ser, por ejemplo, poner un disco a cada lado de la fisura.



- Realizar ensayos similares a los estudiados en este proyecto pero probando con ejes sanos y fisurados y empleando rodamientos tanto nuevos como con algún defecto con el objetivo de comprobar si las redes neuronales consiguen clasificar cada uno de los casos.
- Variar el número de neuronas de la capa oculta para comprobar si los resultados obtenidos al realizar este cambio difieren de los logrados en un primer momento con 20 neuronas ocultas para la red de reconocimiento de patrones.
- Comparar las eficiencias de las redes neuronales conseguidas en el presente proyecto con las alcanzadas con estas mismas redes para otros ensayos como puede ser el caso de rodamientos con fisuras.
- Cambiar el nivel de energía empleado en el programa empleado para realizar la descomposición wavelet con el objetivo de conocer si el hecho de variarlo influye en los resultados obtenidos.
- Un último paso en el desarrollo de estudios como el realizado en este proyecto sería el implementar las redes neuronales empleadas mediante la herramienta Simulink® proporcionada por el propio programa MATLAB® en un sistema real.



# **Capítulo 8:**

---

---

## Bibliografía

**BIBLIOGRAFÍA**

- [1] <http://www.mitecnologico.com/Main/TiposDeMantenimiento>. Última visita: 2 de diciembre de 2010.
- [2] Surajudeen Adedotun Adewusi. *Detection of a Transverse Crack in a Rotating Shaft using Wavelet Transform*. Faculty of the College of Graduate Studies. King Fahd University of Petroleum & Minerals. Dhahran. Saudi Arabia. Mayo, 2000.
- [3] Omar José Lara Castro. *Nuevas Metodologías no Invasivas de Diagnóstico de Defectos Incipientes en Rodamientos de Bola*. Departamento de Ingeniería Mecánica. Universidad Carlos III de Madrid. Mayo 2007.
- [4] Jimmy Alexander Cortés, Hugo Baldomiro Cano Garzón, José Andrés Chaves O. *Del análisis de Fourier a las wavelets – Transformada Continua Wavelet (CWT)*. Scientia Et Technica, diciembre 2007, Año/vol. XIII, número 037, pp. 133-138. Universidad Tecnológica de Pereira, Colombia.
- [5] A. Haar. *Zur Theorie der Orthogonalen Funktionen-systeme*. Mathematics Analysis. 1910.
- [6] A. Grossman, J. Morlet. Decomposition of Hardy functions into square integrable wavelets of constant shape. SIAM J. Math. Anal. 15. 1984
- [7] Stephane Mallat. *A Theory for Multiresolution Signal Decomposition: the Wavelet Representation*. IEEE Transactions on Pattern Analysis and Machine Intelligence. Vol. 2, No. 7, July 1989.
- [8] I. Daubechies. *Orthonormal Bases of Compactly Supported Wavelets*. Communication in Pure and Applied Mathematics. Vol. 41, No. 7, p. 909-996. 1988.
- [9] [http://coco.ccu.uniovi.es/brahms/modelos\\_mat/twc.htm](http://coco.ccu.uniovi.es/brahms/modelos_mat/twc.htm). Última visita: 15 de diciembre de 2010.
- [10] Joaquín López Herraiz. *Wavelets, concepto y aplicaciones para el análisis de señales*. Departamento de Física Atómica, Molecular y Nuclear. Universidad Complutense de Madrid. Octubre 2004.
- [11] Eduardo Pedro Serrano. *Introducción a la transformada wavelet y sus aplicaciones al procesamiento de señales de emisión acústica*. Escuela de Ciencia y Tecnología. Universidad Nacional de General San Martín. Argentina.
- [12] Ramón Ignacio Diego García. *Análisis wavelet aplicado a la medida de armónicos, interarmónicos y subarmónicos en redes de distribución de energía eléctrica*. Departamento de Electrónica y Computadores. Universidad de Cantabria. Santander, octubre 2006.



- [13] Antonio Hernández Sánchez. *Sistema Clasificador de Imágenes en Web. Apéndice A*. Departamento de Ingeniería en Sistemas Computacionales. Universidad de las Américas Puebla. México. Mayo 2005.
- [14] Natalia Nieto, Diana Marcela Orozco. *El uso de la transformada wavelet discreta en la reconstrucción de señales senosoidales*. Scientia Et technica, vol. XIV, número 38, junio 2008, pp. 381-386. Universidad Tecnológica de Pereira, Colombia.
- [15] M. González-Audícana, X. Otazu, O. Fors, A. Seco, R. García. *Bondad de los algoritmos de descomposición wavelet de Mallat y 'à trous' para la fusión de imágenes QuickBird*. Teledetección y Desarrollo Regional. X Congreso de Teledetección. Cáceres, España, 2003. Pp. 295-300.
- [16] Harry Nyquist. *Certain topics in telegraph transmission theory*. Trans. AIEE. Vol. 47, páginas 617-644. Abril de 1928
- [17] Emiliano Aldabas-Rubira. *Introducción al reconocimiento de patrones mediante redes neuronales*. Escuela Universitaria de Ingeniería Técnica Industrial de Terrasa. Universidad Politécnica de Cataluña.
- [18] Damián Jorge Matich. *Redes Neuronales: Conceptos Básicos y Aplicaciones. Cátedra de Informática Aplicada a la Ingeniería de Procesos – Orientación I*. Grupo de Investigación Aplicada a la Ingeniería Química (GIAIQ). Universidad Tecnológica Nacional – Facultad Regional Rosario. Argentina. Marzo 2001.
- [19] Sandra Patricia Daza P. *Redes neuronales artificiales. Fundamentos, modelos y aplicaciones*. Facultad de Ingeniería Mecatrónica. Universidad Militar Nueva Granada. Bogotá, Colombia.
- [20] Salvador Torra Porras. *La siniestralidad en seguros de consumo anual de las entidades de previsión social. Perspectiva probabilística y econométrica. Propuesta de un modelo econométrico neuronal para Cataluña. Capítulo 2*. Departamento de Econometría, Estadística y Economía Española. Universidad de Barcelona. Julio 2003.
- [21] Carlos Alberto Oropeza Clavel. *Modelado y Simulación de un Sistema de Detección de Intrusos Utilizando Redes Neuronales Recurrentes. Capítulo 3*. Departamento de Computación, Electrónica y Mecatrónica. Universidad de las Américas Puebla. México. Mayo 2007.
- [22] Rodrigo Salas. *Redes Neuronales Artificiales*. Departamento de Computación. Universidad de Valparaíso. Chile.
- [23] <http://www.spectraquest.com/spanish/spanish.htm>. Última visita: 12 de diciembre de 2010.
- [24] Manual de especificaciones del motor MARATHON 56T34F5301 J. <http://www.marathonelectric.com/MMPS/details.jsp?item=056T34F5301>. Última visita: 8 de diciembre de 2010.



- [25] Manual del variador de frecuencia Delta VFD 007S21B.
- [26] Jaime Salvadó Ruiz, Marcos Rodríguez Millán, Álvaro Vaz-Romero Santero. *Máquina de simulación de fallos*. Trabajo dirigido del departamento de Ingeniería Mecánica de la Universidad Carlos III de Madrid.
- [27] María Jesús Gonzalo Arribas. *Medida de Aceleración*. Electrónica de potencia y medida. Área de tecnología electrónica. Escuela Técnica Superior de Ingenieros de Minas de Oviedo. 2004/2005.
- [28] Manual del acelerómetro MMF KS943B.10. Diciembre 2009.
- [29] Manual de especificaciones de los filtros MMF M32. Julio 2008.
- [30] Manual de la tarjeta de adquisición de datos Keithley KUSB-3100.
- [31] Manual de referencia del programa TestPoint. *TestPoint QuickStart*. 5ª Edición.
- [32] Descripción de producto de MATLAB®.  
<http://www.mathworks.es/products/matlab/index.html?sec=extending>. Última visita: 8 de diciembre de 2010.
- [33] José L. Cortizo Rodríguez, José E. Fernández Rico, M<sup>a</sup> del Rocío Fernández Rodríguez, Eduardo Rodríguez Ordóñez, José M. Sierra Velasco, Ricardo Vijande Díaz. *Elementos de máquinas. Teoría y problemas*. Área de Ingeniería Mecánica. Universidad de Oviedo. 2004.



# **Capítulo 9:**

Anexos

**ANEXOS****Anexo A: Rotokit**

1. Motor de velocidad variable con interruptor de encendido/apagado y display para el control de la velocidad.
2. Motor.
3. Acoplamiento.
4. Árbol de transmisión.
5. Cojinete partido con cubierta movible (2).
6. Disco giratorio con orificios para desequilibrarlo (2).
7. Anillo de sujeción para ajustar el rotor al eje (2).
8. Tornillos elevadores para introducir desalineamiento (2 axial, 4 horizontal, 4 vertical).
9. Rodamientos (2).
10. Doble polea (pequeñas) granulada para correas en V.
11. Doble polea (grandes) granulada para correas en V.
12. Dobles correas en V.
13. Tensor de correa por palanca.
14. Tensor de correa por polea.
15. Tensor de correa por tornillo para modificar la tensión de la correa.
16. Caja de cambios con ángulo recto.
17. Freno magnéticos: ajustable manualmente desde 0.5 – 10 lb.in;5/8” de diámetro.
18. Apoyo de goma aislante.
19. Base.
20. Plataforma del rotor.
21. Interruptor de seguridad.
22. Rueda articulada por brazo, diámetro 5/8”.
23. Caja de acceso a las conexiones de motor.
24. Soporte de freno magnético.
25. Plataforma de la caja de cambios.
26. Anillo de ajuste de la caja de cambios.
27. Raíles de la plataforma de la caja de cambios.
28. Tornillo elevador de la caja de cambios.
29. Refuerzo de la base.

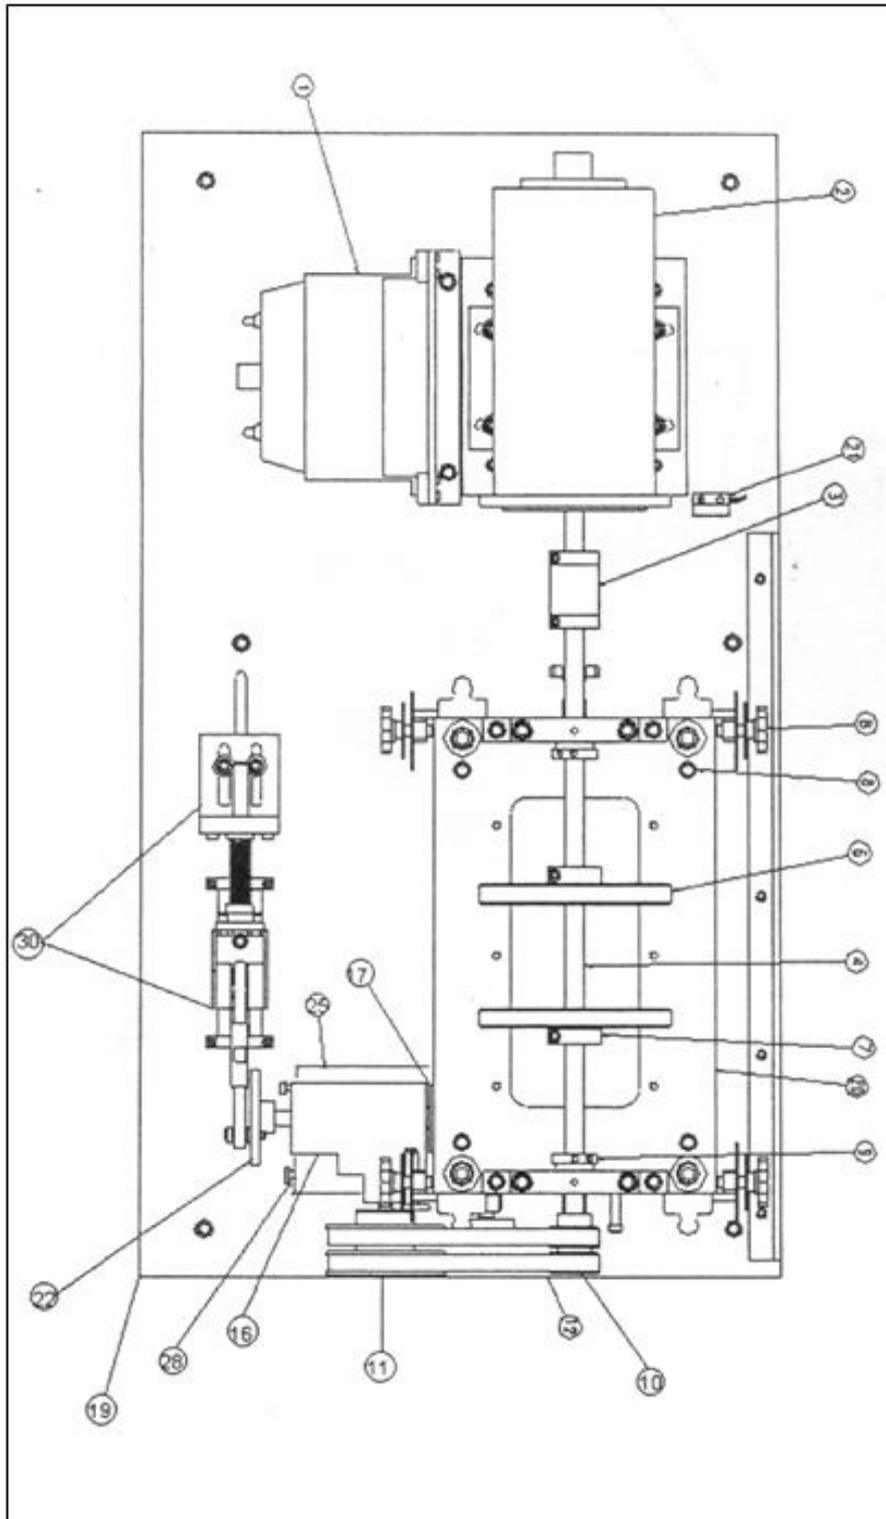


Figura 9.01: Plano superior de la máquina Rotokit.

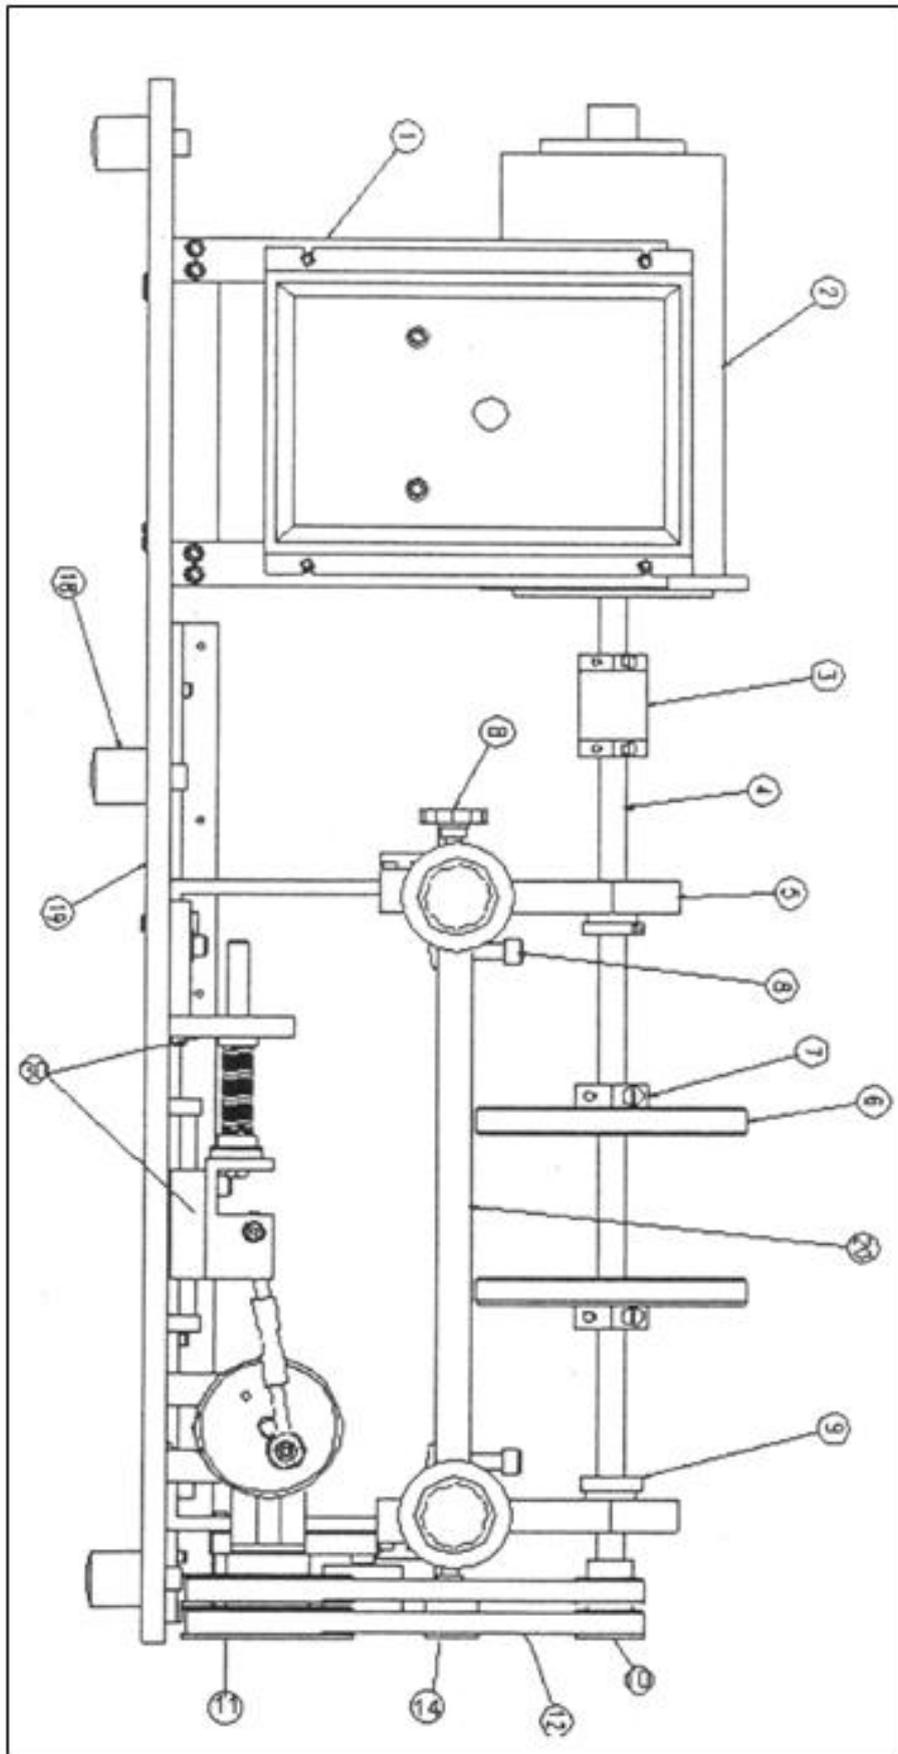


Figura 9.2: Plano frontal de la máquina de ensayos Rotokit.

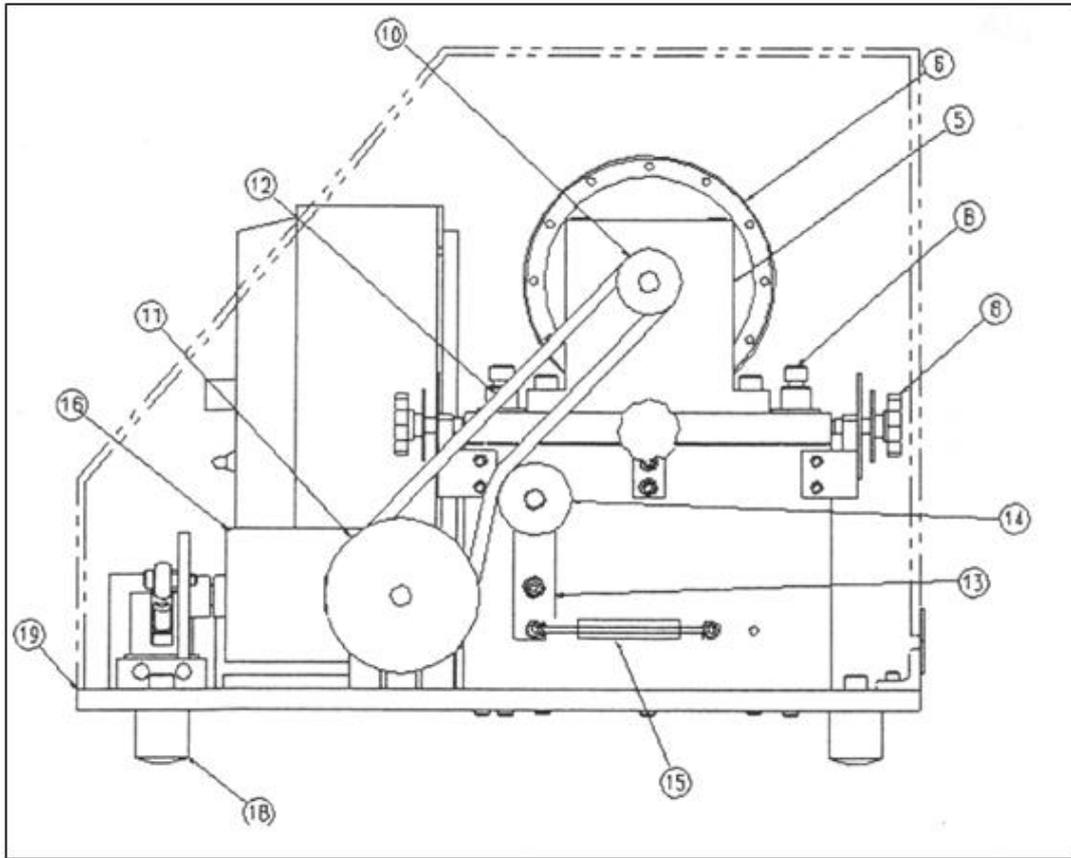


Figura 9.3: Plano lateral del Rotokit.

**Anexo B: Resultados de la red de base radial**

- Resultados de la red neuronal de base radial con los paquetes 1 y 6 incluidos (c.p.).

EJE Y					
Nivel de descomposición		Zona A	Zona B	Zona C	Eficiencia
3	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
4	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
5	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
6	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
7	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
8	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
9	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
10	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
Eficiencia total		100	100	100	100

Tabla 9.1: Resultados de clasificación de una red de base radial para el eje Y (c.p.).



EJE Z					
Nivel de descomposición		Zona A	Zona B	Zona C	Eficiencia
3	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
4	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
5	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
6	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
7	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
8	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
9	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
10	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
Eficiencia total		100	100	100	100

Tabla 9.2: Resultados de clasificación según el eje Z para una red de base radial (c.p.).



- Resultados de la red de base radial sin incluir los paquetes 1 y 6 (*s.p.*).

Nivel de descomposición	EJE X				Eficiencia
		Zona A	Zona B	Zona C	
3	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
4	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
5	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
6	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
7	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
8	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
9	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
10	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
Eficiencia total		100	100	100	100

Tabla 9.3: Resultados de clasificación según el eje X para una red de base radial (*s.p.*).



EJE Y					
Nivel de descomposición		Zona A	Zona B	Zona C	Eficiencia
3	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
4	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
5	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
6	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
7	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
8	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
9	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
10	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
Eficiencia total		100	100	100	100

Tabla 9.4: Resultados de clasificación según el eje Y para una red de base radial (*s.p.*).



EJE Z					
Nivel de descomposición		Zona A	Zona B	Zona C	Eficiencia
3	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
4	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
5	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
6	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
7	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
8	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
9	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
10	Eje sano	100	100	100	100
	Fisura 12.5 %	100	100	100	100
	Fisura 25%	100	100	100	100
	Eficiencia	100	100	100	100
Eficiencia total		100	100	100	100

Tabla 9.5: Resultados de clasificación de una red de base radial según el eje Z (s.p.).