



Universidad de Valladolid

ESCUELA DE INGENIERÍAS INDUSTRIALES

DEPARTAMENTO DE INGENIERÍA ELÉCTRICA

TESIS DOCTORAL:

Aportaciones al mantenimiento
predictivo de motores de
inducción mediante una
metodología de diagnóstico
basada en el uso combinado de
técnicas estadísticas y Redes
Neuronales Artificiales

Presentada por Pedro Esteban Gardel Sotomayor para optar al grado de
doctor por la **Universidad de Valladolid**

Dirigida por:

.....
Daniel Moríñigo Sotelo

.....
Óscar Duque Pérez

Resumen de la tesis

La presente tesis tiene un objetivo principal: desarrollar y validar una metodología de diagnóstico de fallos en motores de inducción útil para el mantenimiento predictivo que funcione en todo el rango de operación del motor, de operación en vacío a plena carga, y que acepte señales obtenidas de motores alimentados tanto de red como de variador de frecuencia. Para concretar este objetivo principal, se dividió al mismo en diferentes objetivos específicos que se desarrollaron de forma progresiva.

Primeramente se realizó un estudio del arte del diagnóstico de fallos en motores de inducción, cuyo resultado se presenta en el tercer capítulo de esta tesis. En esta etapa se vieron las ventajas que presenta la corriente estática como señal a emplear para el diagnóstico, así como la capacidad de las técnicas basadas en Redes Neuronales para clasificar correctamente patrones complejos, como es el caso en estudio, sobre todo al considerar múltiples fuentes de alimentación para el motor.

Seguidamente se ensayó un motor con diferentes estados de fallo, desde motor sano, hasta motor con una barra totalmente rota, pasando por dos estados intermedios de fallo, fallo leve y fallo medio. También se ensayó el motor con niveles de carga que variaron desde operación en vacío hasta plena carga, con 7 alimentaciones diferentes, red y dos variadores de frecuencia a tres frecuencias diferentes cada variador, 35 Hz, 50 Hz y 65 Hz. Además, se emplearon señales de otro motor, que conforman una base de datos preexistente en el departamento. Este segundo motor fue ensayado con estados de fallo similares con 4 alimentaciones diferentes, red y un variador de frecuencia a las mismas 3 frecuencias 35 Hz, 50 Hz y 65 Hz.

Seguidamente, se analizaron las señales obtenidas y se implementaron las técnicas de pretratamiento necesarias, en este caso las Transformadas de Fourier y Hilbert.

A continuación, se calcularon las características indicativas de fallo, tanto en el dominio del tiempo, como del espectro de frecuencia de la señal para seleccionar a continuación y en cada caso, cuáles de estas características eran efectivamente necesarias para el diagnóstico, mediante un Análisis de Correlación Simple y Análisis Discriminante.

Posteriormente se implementó una metodología de clasificación de los ensayos, en los 4 estados de fallos considerados, mediante la utilización de Ensamble de Redes Neuronales, esta metodología forma parte de la propuesta de esta tesis.

Finalmente, se validó la metodología propuesta comparándola con técnicas estadísticas reconocidas, como son el Análisis Discriminante y la Regresión Logística, que tampoco se han empleado de forma profusa en el diagnóstico de máquinas eléctricas. En esta etapa se comprobó el buen rendimiento de la metodología propuesta que fue superior a las dos técnicas estadísticas en todos los casos considerados. Además, mientras más complejo y difícil de diagnosticar es el grupo de ensayos, por ejemplo cuando se consideran ensayos realizados con diferentes tipos de alimentación, como puedan ser red y alimentación con variadores a diferentes frecuencias, la diferencia en el rendimiento es cada vez mayor a favor de la metodología propuesta.

Thesis summary

This thesis has one main objective: to develop and validate a method of fault diagnosis in induction motors useful for preventive maintenance that works throughout the motor operating range, this is, from no load to full load, and accept signals obtained from motors powered both, by direct line and frequency converter. To achieve this objective, it was divided in different specific objectives to be developed progressively.

First, a study of the art of fault diagnosis in induction motors was conducted whose result is presented in the third chapter of this thesis. In this study, it was highlighted the advantages of the stator current as the signal to be used for diagnosis, as well as the ability of neural networks based techniques to correctly classify complex patterns, as is the case under study, especially when considering multiple power sources for the motor.

Then, a motor was tested with different fault states, from healthy motor to a fully broken bar motor, two intermediate failure states, small failure and medium failure were considered. Also, the motor was tested with load levels ranging from no-load to full load, with 7 different operating frequencies, direct line supply and two frequency converters operating at three different frequencies, 35 Hz, 50 Hz and 65 Hz. Also, the signals from a second motor were used; these signals were part of a pre-existing database in the department. This second motor was tested with similar fault states with 4 different power supplies, direct line and a frequency converter at the same three frequencies 35 Hz, 50 Hz and 65 Hz.

Thereafter, the signals obtained were analyzed and the necessary pretreatment techniques were implemented, in this case the Fourier and Hilbert Transforms.

Then, the characteristics indicative of failure in both time domain and frequency domain of the signal were calculated. In each case, a simple correlation analysis and Discriminant Analysis were implemented to determinate which of these features were indeed necessary for diagnosis purposes.

Subsequently, a classification methodology, to discriminate among the four states considered failures, was implemented. This methodology, which is part of the contribution of this thesis, is based on Neural Network Ensembles.

Finally, the proposed methodology was validated by comparison with two known statistical techniques, Discriminant Analysis and Logistic Regression, not very common in the electric motor fault diagnosis field. At this stage, it was verified the good performance of the proposed methodology which was higher than the two statistical techniques in all cases considered. Moreover, the more complex and difficult to diagnose group of tests, for example groups of tests that consider different types of supplies, such as network supply and frequency converters operating at different frequencies, the greater the difference in performance in favor of the proposed methodology is.

Agradecimientos.

A mis tutores, Daniel Moríñigo y Óscar Duque, por su guía y acompañamiento durante estos 3 años, esenciales para la concreción de esta meta.

A los profesores Teodoro Calonge, Miguel Fernández y Luis Ángel García por los consejos brindados durante el desarrollo de esta tesis.

Al grupo de investigación en máquinas e instalaciones eléctricas del Instituto de Ingeniería Energética, de la Universidad Politécnica de Valencia por su apoyo durante mi estancia de investigación

Al consorcio Erasmus Mundus, “Mundus 17”, y al Departamento de Relaciones Internacionales de la Universidad Nacional de Asunción, por la beca que me permitió seguir el doctorado en la Universidad de Valladolid.

A la Facultad Politécnica de la Universidad Nacional de Asunción por el apoyo recibido.

A mis compañeros de la Universidad Nacional de Asunción.

A mis familiares y amigos.

Dedicatoria

A la memoria de mis padres.

A mi esposa Liza Aracelli por su amor y compañía.

Resumen de la tesis	1
Thesis summary	3
Agradecimientos.....	5
Dedicatoria	7
Lista de acrónimos	13
1 Introducción	15
1.1 Justificación.....	15
1.2 Objetivos.....	19
1.2.1 Objetivo general.....	20
1.2.2 Objetivos específicos.....	20
1.3 Procedimiento de trabajo.....	21
1.4 Estructura de la tesis.....	22
2. Motor de inducción y fallos característicos.....	25
2.1 Introducción y características constructivas.....	25
2.2 Fallos en motores de inducción.....	27
2.2.1 Introducción.....	27
2.2.2 Fiabilidad de los motores de inducción.....	28
2.2.2.1 Introducción.....	28
2.2.2.2 Estudios sobre fiabilidad de los motores de inducción.....	29
2.2.2.3 Consideraciones sobre los estudios de fiabilidad en motores de inducción.....	33
2.2.3 Causas de fallos en el motor de inducción.....	34
2.3. Análisis de la corriente del estator.....	37
2.3.1 Efecto producido por las asimetrías del circuito del rotor sobre el campo en el entrehierro.....	37
2.3.2 Armónicos originados por la rotura de una barra del rotor.....	39
2.3.3 Armónicos de la corriente del estator originados por las pulsaciones del par y de la velocidad.....	41
2.4. Procesamiento de señal de la corriente del estator para la obtención de patrones.....	43
2.4.1. Dominio del tiempo.....	43
2.4.2. Dominio de la frecuencia: FFT y Hilbert.....	45
2.4.2.1 La Transformada de Fourier.....	45
2.4.2.2 La Transformada de Hilbert.....	49
3 Estado del arte del mantenimiento y diagnóstico en motores de inducción	53
3.1 Introducción	53
3.2 Dispositivos de adquisición de datos de acuerdo al tipo de efecto medido	55
3.2.1 Emisiones acústicas:.....	55
3.2.2 Par en el entrehierro	56
3.2.3 Corriente en el estator.....	56
3.2.3.1 Análisis en estacionario y transitorio.....	56
3.2.3.2 Vector de Park	61
3.2.3.3 Instantes de cruce por cero (Paso por cero).....	62
3.2.3.4 Envolvente (Envelope)	63
3.2.4 Monitorización del campo electromagnético:	63
3.2.5 Voltaje inducido:	64

3.2.6 Velocidad angular instantánea.....	65
3.2.7 Potencia instantánea	66
3.2.8 Análisis circuital del motor	67
3.2.9 Ensayos de sobretensión (Surge test)	67
3.2.10 Vibraciones.....	68
3.2.11 Voltaje	69
3.2.12 Temperatura.....	69
3.2.13 Análisis de gases.	70
3.2.14 Monitorización mixta	70
3.3 Procesamiento de señales	71
3.4 Técnicas de clasificación.....	74
3.4.1 Detección de barras rotas con redes neuronales.....	77
4 Técnicas de clasificación para el diagnóstico	83
4.1 Introducción	83
4.2 Técnicas Estadísticas: Análisis Discriminante y Regresión Logística.....	83
4.2.1 Introducción.....	83
4.2.2 Análisis discriminante	84
4.2.2.1 Introducción	84
4.2.2.2 Método paso a paso para la selección de variables.....	87
4.2.2.3 Matriz de clasificación.....	91
4.2.3 Regresión Logística.....	93
4.3 Redes Neuronales.....	96
4.3.1 Introducción.....	96
4.3.2 Reseña histórica.....	97
4.3.3 La Neurona Biológica	97
4.3.4 Red Neuronal Artificial.....	98
4.3.5 Métodos de aprendizaje: supervisado o no supervisado	100
4.3.6 Redes neuronales para aprendizaje supervisado	101
4.3.6.1 Tipos básicos de problemas	101
4.3.6.2 El perceptrón multicapa.....	101
4.3.6.3 Redes de base radial.....	107
4.3.7 Generalización.....	108
4.3.7.1 Detención temprana	109
4.3.7.2 Equilibrio sesgo varianza (bias variance trade-off dilemmas)	110
4.3.8 Ensamble de redes neuronales.....	111
5 Influencia de los convertidores de frecuencia en el diagnóstico de motores de inducción	115
5.1. Introducción	115
5.2. Funcionamiento de un convertidor de tensión.	117
5.2.1. Introducción.....	117
5.2.2. Inversor de tensión de dos niveles.....	118
5.3. Contenido armónico de la tensión de salida.....	123
5.4. Sobremodulación.....	128
5.2.5. Inyección del tercer armónico en la onda moduladora.....	129
5.2.6. Otro contenido armónico.....	130
5.3. Efectos del uso del convertidor sobre el funcionamiento del accionamiento.	131
5.4. Efectos del uso del convertidor en el diagnóstico de fallas.	132

6. Propuesta de metodología de diagnóstico de barras rotas en motores de inducción orientada al mantenimiento.	139
6.1 Introducción	139
6.2 Señales a medir	139
6.3 Procesamiento de la señal para extracción de patrones	140
6.3.1 Características indicativas del nivel de carga del motor	140
6.3.2 Características obtenidas del espectro de la corriente	140
a) Características obtenidas mediante la Transformada de Fourier	141
b) Características obtenidas mediante la transformada de Hilbert	142
6.3.3 Características estadísticas en el dominio del tiempo	143
6.4 Método de diagnóstico, basado en Redes Neuronales Artificiales y comparado con Análisis Discriminante y Regresión Logística.	145
6.4.1 Reducción de la dimensionalidad de los datos	147
6.4.2 Comparación de desempeño de los algoritmos.	147
6.4.3 Cálculo del porcentaje de clasificación correcta ponderado.	149
6.4.4 Grupos de pruebas de acuerdo al tipo de alimentación	150
6.4.5 Esquema de monitorización propuesto.....	151
6.5 Enfoque del diagnóstico en función de la importancia de los motores.....	151
7 Ensayos.....	155
7.1. Descripción de los ensayos.	155
7.2. Descripción estadística de los ensayos obtenidos.	158
7.2.1. Motor 1	158
a) Todos los ensayos	158
b) Ensayos con alimentación de red	161
c) Ensayos con alimentación de variador Altivar a 35 Hz.....	163
d) Ensayos con alimentación de variador Altivar a 50 Hz.	165
e) Ensayos con alimentación de variador Altivar a 65 Hz.....	167
7.2.2. Motor 2	170
a) Todos los ensayos.	170
b) Ensayos con alimentación de red	172
c) Ensayos con alimentación de variador Allen-Bradley a 35 Hz.	174
d) Ensayos con alimentación de variador Allen-Bradley a 50 Hz.	176
e) Ensayos con alimentación de variador Allen-Bradley a 65 Hz.	178
f) Ensayos con alimentación de variador Siemens a 35 Hz.	180
g) Ensayos con alimentación de variador Siemens a 50 Hz.	182
h) Ensayos con alimentación de variador Siemens a 65 Hz.	184
7.3 Conclusiones	186
8 Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo	189
8.1 Introducción	189
8.2 Reducción del número de características	192
8.2.1 Análisis de correlación simple.	194
8.2.2 Selección de características por Análisis Discriminante.....	195
8.3 Clasificación por medio de Análisis Discriminante.....	202
8.3.1 Alimentación con red.	202
a) Motor 1	202
b) Motor 2	204
8.3.2 Resumen con las diferentes combinaciones de alimentaciones consideradas.	206

a) Ensayos Alt 65	206
b) Ensayos AB	207
c) Ensayos SM50 Hz	209
8.4 Clasificación por medio de Regresión Logística.	212
8.4.1 Alimentación con red.	212
a) Motor 1	212
b) Motor 2	214
8.4.2 Resumen con las diferentes combinaciones de alimentaciones consideradas.	215
a) Ensayos Alt.....	216
b) Ensayos M2 a 35 Hz.....	217
c) Ensayos AB 50	219
8.5 Clasificación por medio de Red Neuronal.	223
8.5.1 Optimización del número de neuronas en la capa oculta	224
8.5.2 Alimentación con red.....	227
a) Motor 1	227
b) Motor 2	230
8.5.3 Resumen con las diferentes combinaciones de alimentaciones consideradas.	232
a) Todos los ensayos del Motor 2	233
b) Ensayos AB a 35 Hz.....	236
c) Ensayos SM	238
8.6 Comparación de los clasificadores considerados.	243
8.6.1 Alimentación con red.	245
a) Motor 1	246
b) Motor 2	248
8.6.2 Alimentación con Siemens a 65 Hz	249
8.6.3 Alimentación con Allen Bradley.....	252
8.6.4 Motor 2 con alimentación a 35 Hz	255
8.6.5 Promedio de todos los casos considerados.....	257
8.6.6 Conclusión de la comparación de algoritmos:	260
9 Conclusiones y trabajos futuros	263
9.1 Aportaciones y conclusiones.....	263
9.2 Trabajos futuros	268
Referencias	271
Anexo I: Banco de ensayos	293
Anexo II: Resultados del Análisis de Correlación.....	307
Anexo III: Resultados de los algoritmos estudiados.....	311

Lista de acrónimos

ANN	: Red neuronal artificial (<i>Artificial Neural Network</i>)
APVD	: Absolute phase value difference
BR	: Barras rotas
BP	: Backpropagation network
fs	: frecuencia fundamental
IA	: Inteligencia Artificial
MCSA	: Análisis espectral de la corriente del motor (<i>Motor current signature analysis</i>).
MI	: Motor de inducción
MLP	: Red Perceptrón Multicapa
PI	: Potencia instantánea
VAI	: Variación angular instantánea.

1 Introducción

1.1 Justificación.

Los motores eléctricos son los mayores consumidores de energía eléctrica tanto en el sector industrial como en el comercial. Casi la mitad de la energía eléctrica usada y cerca de las dos terceras partes de la utilizada en la industria es consumida por motores eléctricos.

Los motores de inducción de jaula de ardilla son los más usados en diferentes aplicaciones industriales, y tradicionalmente han sido considerados como máquinas con un índice de averías muy bajo, ya que debido a sus características constructivas son los más robustos, y por tanto, los que menor mantenimiento precisan. Sin embargo, la tendencia actual a reducir los costes, hacia una producción de mayor calidad y a evitar las interrupciones en los procesos de producción, ha hecho que cada vez sea más necesario controlar el funcionamiento interno de las máquinas, y así poder detectar cualquier posible indicio antes incluso de que se produzca el fallo.

Todo esto ha llevado a tratar de reemplazar el mantenimiento preventivo, que se basa en la sustitución programada de piezas susceptibles de sufrir una avería, lo cual provoca un desaprovechamiento en el uso de estos elementos, hecho que va en contra de la reducción de costes que se busca. Así, el mantenimiento preventivo ha evolucionado hacia la vigilancia y control de determinados parámetros o variables de funcionamiento, los cuales van a determinar el momento adecuado para intervenir y así corregir lo que en un futuro sería una probable avería. Esto es lo que se conoce como mantenimiento predictivo. Además, también hace posible conocer con antelación las piezas de recambio que se necesitarán, evitando las paradas innecesarias y la disminución de los stocks para realizar correctamente el mantenimiento.

Aunque los motores de inducción son muy fiables, también pueden sufrir fallos y averías. Existen diversas técnicas para detectar fallos en estos motores (que posteriormente se podría aplicar en el mantenimiento predictivo) tales como el análisis de vibraciones, el análisis de la temperatura y la técnica conocida como MCSA correspondiente a sus siglas en inglés: Motor Current Signature Analysis. MCSA, que se basa en el análisis de la corriente del estator, presenta varias ventajas frente a los otros métodos: es un procedimiento no invasivo, puesto que la corriente se puede medir

Capítulo 1: Introducción.

con una pinza amperimétrica y puede emplearse para diagnosticar fallos en línea, incluso en tiempo real, por lo que no requiere realizar paradas de mantenimiento innecesarias.

Los variadores de velocidad (también conocidos como variadores de frecuencia o convertidores de tensión) son usados para regular la velocidad de trabajo de los motores, permitiendo significativos ahorros energéticos y, por tanto, la reducción de costes de operación en aquellas máquinas accionadas por motores eléctricos que no trabajan a plena carga la mayor parte del tiempo. El uso de esta tecnología aporta otros beneficios adicionales, como son la mejora de la calidad del producto y la fiabilidad del sistema, o la prolongación de la vida útil de los equipos. Por estas razones, su uso está cada vez más generalizado en la industria.

Estudios recientes indican que el 90% de los fallos en las máquinas de inducción ocurren a raíz del funcionamiento anormal de los componentes internos. Los principales fallos mecánicos son: problemas de rodamientos, barras rotas, excentricidades, obstrucción de la ventilación, etc. Se sabe que aproximadamente el 50% de las averías en las máquinas eléctricas se deben a problemas en los rodamientos, y aunque solamente el 10% son achacables a problemas en las barras o en los anillos, es importante señalar que, aunque tengan un escaso porcentaje de incidencia, se trata de un tipo de fallo muy grave debido a que sus consecuencias sobre la integridad de la máquina son catastróficas.

El desarrollo de una avería en los motores de inducción produce variaciones en el campo magnético del motor, que se traduce en la aparición de armónicos. Estos, a su vez, inducen fuerzas magnetomotrices que finalmente dan lugar a la aparición de armónicos en la corriente de alimentación del motor. En el caso de asimetrías en el rotor (rotura de barras), el fallo se manifiesta en forma de bandas alrededor del armónico fundamental, e incluso de algunos armónicos enteros superiores.

Para analizar la corriente normalmente se emplean técnicas basadas en la transformada de Fourier. En este caso, emplearemos la Densidad de Potencia Espectral (PSD) para destacar la amplitud de los armónicos de fallo, respecto a los armónicos fundamental y sus enteros. La amplitud del armónico de fallo, que indica la severidad del mismo, depende del nivel de carga del motor. Cuando los motores se alimentan directamente de red, debido a la contaminación armónica provocada por otros equipos (principalmente

informáticos y otras cargas no lineales) la tensión no es senoidal pura. Los armónicos de la corriente consumida por estos equipos se agregan en el transformador de la instalación y acaban deformando la tensión en el secundario del mismo. Esta técnica está probada en motores alimentados de red, y también puede emplearse en motores alimentados por convertidor. Aunque esta situación presenta algunos inconvenientes que impiden realizar un buen diagnóstico, como es la presencia de un ruido elevado o la introducción por parte del convertidor de armónicos próximos a los indicativos del fallo.

La observación del fallo en el dominio de la frecuencia depende del nivel de carga del motor. A deslizamientos bajos, las bandas indicativas del fallo están muy cerca del armónico principal. La dispersión de la energía de éste hacia valores de frecuencia laterales puede ocultar la presencia de estos armónicos. Nuevas técnicas numéricas, como la Transformada de Hilbert, se están empleando para superar este inconveniente.

En este caso, se está empleando la transformada de Fourier para extraer los patrones (amplitudes a las frecuencias de fallo) que luego permiten realizar el diagnóstico del estado de la máquina. Esta transformada, muy conocida y empleada en la industria, presenta algunas desventajas. Para obtener una buena resolución en frecuencia es necesario medir en estado estacionario durante un tiempo largo. Si se producen oscilaciones en la carga del motor, se pueden falsear las medidas. Por esta razón, y otras no mencionadas, se están aplicando otras técnicas que tienen un coste computacional elevado: Wavelet, Wigner-Ville, MUSIC, Empirical Mode Decomposition, Hilbert, Hilbert-Huang (por nombrar algunas).

Algunos autores también han sugerido la utilización de datos estadísticos, medidos directamente sobre la onda temporal de la corriente del estator. Esta técnica es más común en otras áreas, como el análisis de vibraciones, pero puede aportar información, con bajo coste computacional, que puede ser útil para realizar un diagnóstico del motor.

Hasta ahora, se han mencionado diversas técnicas de detección de fallos, pero el objetivo para cualquier sistema de mantenimiento es disponer de una herramienta que sea capaz de ofrecer un diagnóstico fiable sobre el estado del motor.

Los objetivos básicos del método de diagnóstico son determinar si hay una situación anormal de funcionamiento, conocer qué elemento está fallando y cuál es la severidad del fallo. Es necesario conocer la confianza de la información proporcionada por el

diagnóstico y a partir de ahí, establecer los siguientes pasos dentro de la política de mantenimiento.

Los procedimientos o métodos de diagnóstico pueden basarse en datos o en modelos. Estos últimos precisan de un modelo de la máquina que se esté ejecutando en paralelo con la máquina real. Las observaciones se emplean para alimentar el modelo y el diagnóstico se basa en la diferencia entre el modelo y la máquina real.

Las técnicas de diagnóstico basadas en datos obligatoriamente precisan de una primera etapa donde se entrena el algoritmo. Para realizar este entrenamiento se precisan observaciones y datos del funcionamiento de la máquina en todos los posibles estados que se quieran monitorizar. A partir de las observaciones para el entrenamiento se extraen los patrones que se emplean para entrenar el algoritmo.

En resumen, se podría esquematizar el diagnóstico de fallos orientado al mantenimiento preventivo de un motor de inducción en los siguientes pasos (ver Fig. 1.1):

1. Primero es necesario determinar qué señales físicas pueden contener información sobre el estado del motor: corriente del estator, flujo magnético, temperatura, vibraciones, etc.
2. Registro de las señales: se registran de forma adecuada las señales indicativas del estado del motor, mediante pinzas amperimétricas, bobinas para medir el flujo magnético, sensores de vibraciones etc.
3. Preprocesamiento de las señales: se preprocesa la señal original mediante filtros para eliminar ruidos o mediante transformadas como la de Fourier o Hilbert para obtener información del espectro de frecuencia de la señal.
4. Extracción de patrones: en el dominio el tiempo generalmente se realiza aplicando directamente formulas estadísticas para calcular valores como la Curtosis o el Skewness de la señal; en el dominio de la frecuencia se calcula la amplitud de ciertas bandas laterales a frecuencias determinadas por el tipo de fallo, o el cálculo de otros índices basados en el espectro de frecuencias de la señal.
5. Método de diagnóstico: en esta etapa se realiza el reconocimiento de la falta, su clasificación y la estimación de su severidad, si es necesario. Esta información sirve para tomar una decisión dentro de una determinada política de

mantenimiento, considerando factores diversos, como la importancia del motor, el costo del mantenimiento, el cronograma de trabajo de la industria, etc.

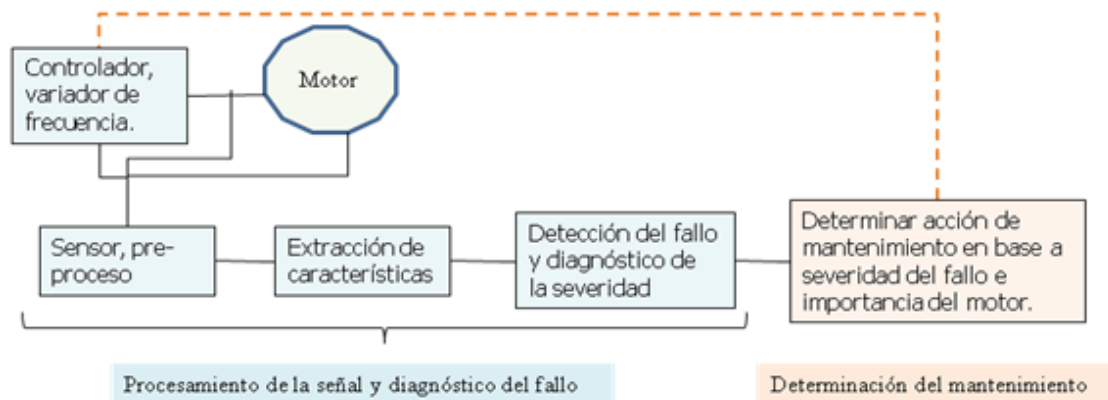


Figura 1.1 Esquema del diagnóstico basado en datos para el mantenimiento preventivo de un motor de inducción.

Para realizar la clasificación de la falta se pueden emplear muchos métodos, basados en algoritmos estadísticos, como el Análisis Discriminante Lineal, Regresión Logística, Árboles de Decisión entre otros, o basados en la Inteligencia Artificial como las Redes Neuronales Artificiales o Máquinas de Vectores de Soporte. En esta etapa de clasificación del fallo se han realizado muchas investigaciones, varias de las cuales han evidenciado el alto rendimiento de las metodologías basadas en Inteligencia Artificial debido a la capacidad de las mismas de aproximar funciones complejas y con alto contenido de ruido (una explicación más detallada de este punto se dará en el capítulo 3 de la presente tesis).

Considerando la importancia de los motores de inducción y la cada vez mayor utilización de los variadores de frecuencia, la industria está siempre en busca de nuevas metodologías de diagnóstico, especialmente orientadas al mantenimiento predictivo, que permitan detectar y seguir la evolución de fallos incipientes, aun cuando el motor deba operar a distintas frecuencias y en un rango amplio de nivel de carga. Con estas metodologías se pretende reducir costos de mantenimiento y ocasionados por fuera de servicios imprevistos debido a averías graves no detectadas a tiempo.

1.2 Objetivos.

Entre los objetivos podemos discriminar entre el objetivo general, cuya consecución es la principal meta de esta tesis, y los objetivos específicos, que son necesarios para la realización del objetivo general.

1.2.1 Objetivo general.

Desarrollar, implementar y validar una metodología de diagnóstico de fallos en motores basado en el uso combinado de técnicas estadísticas y Redes Neuronales Artificiales, orientada al mantenimiento predictivo, que sea robusta ante señales de entradas no ideales y de motores con diferentes tipos de alimentación y que funcione con régimen de operación del motor de plena carga a operación en vacío.

1.2.2 Objetivos específicos.

Los objetivos específicos que deberán desarrollarse para conseguir el objetivo general son:

- Realizar un estudio del estado del arte del diagnóstico de fallos en motores de inducción. El resultado de este objetivo es un resumen que se presenta en los primeros capítulos de la presente tesis, así como la determinación de las señales a ser empleadas por la metodología de diagnóstico además de las posibles características o patrones indicativos de fallo.
- Obtener una base de datos con ensayos de motores operando con niveles de carga que vayan de operación en vacío a plena carga y con diferentes tipos de alimentación, como es la alimentación de red y con variadores de frecuencia operando a diferentes frecuencias. Para conseguir este objetivo se utilizó una base de datos ya existente en el Departamento de Ingeniería Eléctrica de la Universidad de Valladolid y se realizaron más de 1600 ensayos a un nuevo motor con cuatro estados de fallo, Sano, Fallo Leve, Fallo Medio y Barra Rota, a diversos niveles de carga y con alimentación de red y dos variadores de frecuencia a tres frecuencias diferentes.
- Implementar las técnicas de preprocesamiento de las señales requeridas para la obtención de las características indicativas de fallo. Esta etapa corresponde a la implementación de las transformadas de Fourier y Hilbert a fin de obtener los patrones en el dominio de la frecuencia.
- Calcular los patrones o características indicativas de fallo de las señales tanto en el dominio del tiempo, directamente de la señal medida, como en el dominio de la frecuencia, en base a la señal preprocesada.

- Elaborar un procedimiento para la selección de las características relevantes para el diagnóstico de entre las características inicialmente calculadas. Este objetivo involucra la implementación de un Análisis de Correlación Simple de las características y de un Análisis Discriminante para la selección de las características.
- Implementar una metodología basada en Redes Neuronales Artificiales para clasificar a las características obtenidas en los estados de fallo considerados.
- Validar la metodología propuesta comparándola con técnicas estadísticas clásicas, de reconocida eficiencia, como el Análisis Discriminante y la Regresión Logística.

1.3 Procedimiento de trabajo.

El procedimiento de trabajo seguido para la presente tesis se describe en las siguientes cinco etapas:

1. Se realizó un estudio del estado del arte del diagnóstico de fallos en motores de inducción. Es bien sabido que la finalidad de este estudio es obtener una visión global sobre el tema, que permita dirigir los esfuerzos de la tesis a resolver problemas con una consistencia científica comprobada, de modo que las aportaciones de la tesis constituyan un avance en el estado del arte del tema, acordes con las tendencias actuales. En esta etapa se identificaron las características indicativas de fallo a ser utilizadas en las etapas siguientes.
2. Se emplearon señales obtenidas en dos motores. Señales de un motor que forman parte de una base de datos preexistente en el Departamento de Ingeniería de la Universidad de Valladolid. Además, se realizaron numerosos ensayos a un segundo motor con cuatro estados de fallos, Motor Sano, Fallo Leve, Fallo Medio y Barra Rota, para emplear las señales obtenidas en las metodologías de diagnóstico.
3. Se procesaron las señales de la corriente estatórica de los ensayos para calcular las características indicativas de fallo seleccionadas en base al estudio realizado en la primera etapa. Seguidamente, se efectuó un análisis de las características obtenidas de los ensayos de ambos motores, donde se estudió el poder discriminante de las características indicativas de fallo y las relaciones existentes entre las variables y el nivel de carga del motor.

4. Se implementaron las técnicas de diagnóstico estudiadas en la presente tesis: Análisis Discriminante, Regresión Logística, Redes Neuronales simples y Ensemble de Redes Neuronales. En esta última técnica se basa la metodología propuesta en la presente tesis.
5. Se analizaron los resultados obtenidos en la etapa previa para valorar la principal aportación del presente trabajo: una metodología de diagnóstico de fallos incipientes en motores de inducción orientado al mantenimiento predictivo, basado en Ensemble de Redes Neuronales.

1.4 Estructura de la tesis.

La presente tesis está estructurada de la siguiente forma:

En el capítulo 2 se presenta una sucinta descripción de los motores de inducción, seguidamente se describen los tipos de fallos más comunes que afectan a los motores de inducción. En la siguiente sección se describe el efecto de las asimetrías del rotor sobre el campo en el entrehierro y se explican los armónicos originados por la rotura de barras. Posteriormente se describe el procesamiento de la señal realizado para obtener las características indicativas de fallo, tanto en el dominio del tiempo como de la frecuencia.

En el capítulo 3 se presenta una descripción del estado del arte del diagnóstico de fallos en motores de inducción haciendo especial énfasis en las técnicas de diagnóstico de barras rotas basadas en redes neuronales.

En el capítulo 4 se describen los métodos de diagnóstico empleados en la presente tesis. Primeramente se presentan las técnicas estadísticas, Análisis Discriminante y Regresión Logística, para luego explicar la teoría de las Redes Neuronales y de los Ensamblados de Redes Neuronales.

En el capítulo 5 se describe el principio de funcionamiento de los variadores de frecuencia mostrándose también su influencia en el diagnóstico de fallos.

El siguiente capítulo, el 6º, presenta la metodología propuesta, y principal aportación de esta tesis, para el diagnóstico de barras rotas. Primeramente se describen las señales a medir, seguidamente se expone el procesamiento de señales empleado para la obtención de las características de fallo utilizadas por los algoritmos clasificadores. A

Capítulo 1: Introducción.

continuación se describen las metodologías de diagnóstico basadas en Análisis Discriminante, Regresión Logística, Redes Neuronales y Ensamblados de Redes Neuronales. Al final del capítulo se presenta el enfoque del diagnóstico en función de la importancia de los motores propuesto en esta tesis.

En el capítulo 7 se describen los ensayos empleados en la presente tesis. Se presenta una descripción estadística de los mismos haciendo énfasis en la complejidad del problema de diagnóstico incipiente de barras rotas.

El siguiente capítulo, el 8º, presenta los resultados de los algoritmos empleados en esta tesis. Primeramente se exponen los resultados de las técnicas estadísticas, Análisis Discriminantes y Regresión Logística, seguidamente se muestra el rendimiento de las Redes Neuronales simples y de la metodología propuesta basada en Ensamblados de Redes Neuronales. Al final del capítulo se comparan los resultados de las diferentes metodologías empleadas mostrándose las ventajas de la metodología propuesta.

Finalmente, el capítulo 9, describe las aportaciones de la presente tesis, muestra las conclusiones del trabajo y los posibles trabajos futuros para seguir con línea de investigación de esta tesis.

2. Motor de inducción y fallos característicos.

En el presente capítulo se describe brevemente al motor de inducción. Luego se detallan los fallos más comunes que presentan este tipo de máquinas, analizando las causas que generalmente provocan dichos fallos. Esta tesis propone una metodología de diagnóstico para fallos en motores de inducción con señales de la corriente como fuente de características de fallo, para probar la eficacia de la técnica propuesta se emplean ensayos de motores con barras rotas. Considerando esto, se presenta un análisis del efecto de las barras rotas en la corriente estatórica. Finalmente, se describen las técnicas de procesamiento de la señal de corriente empleadas para la obtención de características de fallo.

2.1 Introducción y características constructivas

El motor de inducción es el motor eléctrico más ampliamente utilizado en la industria, abarcando aproximadamente un 85% del total de las cargas eléctricas. Es utilizado en una gran variedad de aplicaciones como medio para proporcionar potencia mecánica, como pueden ser el accionamiento de bombas, elevadores, cintas transportadoras, sistemas de ventilación, aire acondicionado, etc.

Desde un punto de vista constructivo, al ser una máquina eléctrica rotativa, dispone de un estator y de un rotor. En el estator se coloca el bobinado o devanado inductor, que suele ser trifásico y con conexión en estrella o triángulo. Este bobinado, que es de tipo distribuido, se coloca sobre la superficie interior ranurada del circuito magnético laminado del estator. El rotor se coloca en el interior del estator, dejando en esta máquina un entrehierro lo más pequeño posible. Existen, principalmente, dos variantes constructivas del rotor: rotor de jaula de ardilla y rotor bobinado. En la variante de rotor bobinado, el circuito eléctrico es también trifásico de tipo distribuido que se monta sobre las ranuras del circuito magnético laminado del rotor. El circuito eléctrico se suele conectar en estrella y los extremos libres se conectan a un colector de anillos. Éste permite modificar las características de funcionamiento de la máquina, como son la corriente de arranque y velocidad de giro, añadiendo una resistencia interna.

Sin embargo, es la variante de jaula de ardilla la más empleada a nivel industrial, debido a que presenta la gran ventaja de ser un motor de construcción simple, robusto, de bajo coste y que requiere un mantenimiento mucho menor que cualquier otra máquina

rotativa al carecer de escobillas, colector de anillos o colector de delgas. Si además se tienen en cuenta su menor peso y tamaño, y el desarrollo espectacular de la electrónica de potencia y control, actualmente es insustituible en todo tipo de aplicaciones industriales. La jaula puede ser de aluminio o cobre y puede ser construida mediante técnicas de moldeo o inyección, o mediante la soldadura de barras de cobre a los anillos laterales, una vez introducidas en las ranuras del rotor.

El principio de funcionamiento de esta máquina es muy sencillo. El bobinado trifásico del estator, cuando es alimentado por un sistema de tensiones trifásico equilibrado, produce en el entrehierro un campo magnético giratorio. Este campo gira a la denominada velocidad de sincronismo (n_1), impuesta por la frecuencia de la alimentación (f_1) y el número de pares de polos de la máquina (p). Este campo magnético giratorio es variable en el tiempo para el circuito eléctrico del rotor y, por lo tanto, induce un sistema de corrientes en él. Bajo la acción de las corrientes inducidas y el campo magnético giratorio, se genera un par sobre el rotor que lo impulsa a girar en el mismo sentido que dicho campo magnético. El rotor girará a una velocidad inferior (n) a la velocidad de sincronismo, puesto que si lo alcanzara no habría corrientes inducidas, y por tanto desaparecería el par motor. La diferencia entre la velocidad de giro del rotor y la velocidad de sincronismo se caracteriza por un parámetro adimensional denominado deslizamiento (s) y definido por $s = (n_1 - n) / n_1$.

Si el rotor girase a la velocidad de sincronismo, el deslizamiento valdría 0, y vale 1 justo en el instante de arranque. Cuanto mayor es el par resistente del motor, más se retrasa el rotor respecto del campo magnético giratorio, y el deslizamiento crece (también la corriente consumida por el motor). Dependiendo del tamaño y potencia del motor, se trabaja habitualmente con deslizamientos en el rango 0 (vacío) y 0,1 (como mucho) a plena carga.

El motor está formado por una serie de elementos, muchos de los cuáles son susceptibles de fallo, como se comentará posteriormente en este mismo capítulo. Se pueden nombrar los siguientes: rodamientos; eje; circuito magnético del rotor y del estator formado por láminas ranuradas de acero magnético aisladas eléctricamente entre sí (Fig. 2.1); circuito eléctrico del estator en forma de bobinado trifásico distribuido; circuito eléctrico del rotor en forma de jaula de ardilla (Fig. 2.2) o bobinado distribuido (en este caso también hay un colector de anillos); sistema dieléctrico o aislante de los

circuitos eléctricos; carcasa protectora; bornero de conexiones; sistema de refrigeración; sistema de sujeción mecánica (patas o bridas).




Figura 2.1. Láminas de acero de un motor de inducción: (a) estator y (b) rotor [NAM10].




Figura 2.2. Rotor de jaula de ardilla de un motor de inducción [DUQ05].

2.2 Fallos en motores de inducción

2.2.1 Introducción

El motor de inducción no está exento de averías, cuya causa habitual es la aplicación de esfuerzos en los devanados del estator, núcleos magnéticos, jaula, rodamientos y eje, más elevados o durante un tiempo más prolongado que para los que han sido diseñados. Si estos esfuerzos se encuentran dentro del rango establecido en el diseño y la aplicación del motor es la correcta, no debe producirse un fallo prematuro. Pero si uno de estos esfuerzos o la combinación de varios excede el rango de valores de diseño, la

vida útil del motor puede reducirse de forma drástica y producirse una avería catastrófica.

2.2.2 Fiabilidad de los motores de inducción

2.2.2.1 Introducción

Existen relativamente pocos datos y estudios publicados sobre la fiabilidad de los motores eléctricos en general y del motor de inducción en particular. A su vez, estos estudios reflejan importantes discrepancias en parte de las conclusiones obtenidas, cuestiones estas que deben exigir primero una reflexión sobre los mismos y, en segundo lugar, una revisión enfocada hacia los equipos y aplicaciones actualmente utilizados [DUQ02a].

La fiabilidad de un equipo industrial puede cuantificarse a tres niveles: componentes, sistema funcional o como unidad global, en función del alcance del estudio, del detalle deseado y de los datos históricos de que se disponga.

Si lo que se pretende es realizar un estudio de la fiabilidad del motor que permita mejorar sus prestaciones, particularmente mediante una redefinición de la política de mantenimiento, será necesario considerar la fiabilidad individual de componentes considerando al motor de inducción como un sistema a analizar.

Si consideramos el motor de inducción compuesto por una serie de subsistemas agrupados según un criterio funcional, desde el punto de vista del análisis de fiabilidad podemos interpretar el motor como la agrupación en serie de los subsistemas. No obstante, es necesario reseñar que las tasas de fallo de los subsistemas no son independientes entre sí pues una incidencia en un componente del motor puede significar el deterioro de otro, aumentando así su tasa de fallo. Por ejemplo, la rotura de una barra del rotor puede provocar el sobrecalentamiento del devanado del estator; unos rodamientos desalineados pueden afectar al rotor y al estator, los sobrecalentamientos y vibraciones del motor pueden alterar el funcionamiento de los sensores, etc. y sobre todo, existe una fuerte interacción entre el convertidor estático y el motor.

Además, hay que tener en cuenta en la valoración de la tasa de fallo de cada elemento, la incidencia que tiene sobre la misma la precisión en su montaje. En este sentido puede

citarse cómo, de acuerdo con datos facilitados por fabricantes de rodamientos, el 40% del fallo de éstos es debido a un deficiente montaje. [SKF94]

2.2.2.2 Estudios sobre fiabilidad de los motores de inducción

El primer estudio importante sobre fiabilidad de los equipos eléctricos utilizados en aplicaciones industriales aparece en 1962 [DIC62], trabajo que será posteriormente actualizado y ampliado en un extenso trabajo publicado por la IEEE entre 1973 y 1974. Un resumen de los datos estadísticos de mayor interés puede encontrarse en la norma IEEE Standard 493-1980. Sin embargo, los resultados de estos estudios han sido cuestionados en distintos aspectos, debido principalmente a la considerada insuficiencia de datos recogidos, lo que les confiere fundamentalmente sólo un interés “histórico”. Posteriormente, en 1983 y restringiéndose únicamente a motores eléctricos, de nuevo la IEEE a través del “Motor Reliability Work Group” realiza un estudio basado en la recolección de datos referentes a 1141 motores de potencia que superaban los 200 HP y con tiempos de funcionamiento inferiores a los 15 años, correspondientes a 75 instalaciones de 33 empresas comerciales e industriales [IEE85]. En 1985, se profundiza en los datos recogidos distinguiendo entre los resultados correspondientes a los distintos tipos de motores, particularmente entre motores de inducción y síncronos, de acuerdo con las condiciones de trabajo de los mismos (número de arranques, velocidad, factor de servicio, etc.) y discriminando por las causas origen de las averías y el entorno de trabajo del motor [IEE87].

De forma paralela, el “Electric Power Research Institute” (EPRI) auspicia otro trabajo que realiza la compañía “General Electric” y que se publica en 1983 [ALB83]. En este caso, el estudio comprende una población de 4797 motores con potencias superiores a los 100 HP, de 132 instalaciones pertenecientes a 56 empresas de generación de energía eléctrica. Los motores estudiados son, casi en su totalidad, motores de inducción con el rotor de jaula de ardilla (aproximadamente el 97% de los motores estudiados). En 1985 se publica una versión ampliada [EPR85], donde se extienden los datos recogidos a un total de 6312 motores, correspondientes a 168 instalaciones de 65 empresas, contribuyendo de esta forma a aumentar la fiabilidad de los resultados.

Posteriormente a estos trabajos, han surgido otros estudios de fiabilidad en motores, pero en general se trata de estudios específicos de determinadas industrias y organismos, con un alcance más limitado. Se puede citar el realizado por O.V. Thorsen

y M. Dalva en 1994 [THO95] y 1997 [THO97a] sobre motores de inducción utilizados en la industria petroquímica y otras industrias de producción, transformación y distribución de energía.

La comparación de los estudios antes citados nos muestra una serie de coincidencias que proporcionan seguridad y confianza sobre los mismos. Sin embargo, también aparecen discrepancias importantes, las cuáles deben ser explicadas y revisadas. La Tabla 2.1 presenta en sus primeras columnas los datos iniciales de los trabajos de la IEEE y de la EPRI. El primer valor que llama la atención es la diferente tasa de fallo resultante de ambos estudios. Esta divergencia podría en parte ser explicada por el distinto criterio utilizado por la EPRI, basado en el suceso del primer fallo, que según estos estudios, se caracteriza por presentar distinta distribución respecto a la que corresponde a las averías sucesivas. No obstante, aun adoptando el mismo criterio que el de la IEEE, la tasa de averías sería de 0,049 averías/unidad año, todavía bastante inferior a la calculada por la anterior entidad. Por otra parte, aunque los datos globales corresponden a motores de todos los tipos (especialmente en el trabajo de la IEEE), si se considerasen sólo los motores de inducción con el rotor de jaula, los resultados se mantendrían prácticamente invariables.

Si observamos los resultados del estudio más reciente realizado por Thorsen y Dalva (última columna de la Tabla 2.1), la tasa de fallo obtenida corresponde a un valor intermedio entre los dos anteriores (0,058 averías/unidad año), aunque hemos de tener en cuenta que ahora la muestra de motores analizados corresponde exclusivamente a motores utilizados en la empresa petroquímica. Para este tipo de industria, la IEEE obtiene una tasa de averías de 0,0801 averías/unidad año, en motores que trabajan con tensiones de hasta 1000 V y de 0,0805 unidades/averías año para motores con tensiones superiores. Es decir, ciñéndonos a poblaciones de motores utilizados en el mismo ámbito industrial, los resultados tampoco coinciden, aunque podría en este caso justificarse la divergencia por la introducción de nuevas y mejoradas tecnologías en la fabricación de motores en el intervalo de tiempo que separa ambos estudios y, en que también en estos años, se han mejorado los programas de mantenimiento. En todo caso, cualquier conclusión que se realice al respecto es, cuanto menos, aventurada.

La influencia de la potencia y de la velocidad de giro del motor sobre la tasa de averías se resume en la Tabla 2.2 (recogida a partir del estudio de la IEEE), donde se muestra

Capítulo 2: Motor de Inducción y Fallos característicos

cómo se obtienen los mejores índices de fiabilidad para los motores de mayores potencias. Aunque, de nuevo, este resultado debe interpretarse con precaución, pues los motores de gran tamaño suelen corresponder en su práctica totalidad a motores considerados “críticos” y por lo tanto sujetos a un cuidadoso mantenimiento y protección. Este dato es corroborado también por el trabajo realizado por Thorsen y Dalva en 1997, según se muestra con mayor detalle en la Tabla 2.3 respecto a los intervalos de potencia manejados.

Tabla 2.1. Principales estudios sobre fiabilidad en motores eléctricos. [IEE85], [EPR85] y [THO97a].

	IEEE (1985)	EPRI (1985)	Petroquímica
Número de motores	1141	6312	356
Potencia de los motores	>200 HP	>100 HP	>100 HP
Edad de los motores	<15 años	<10 años	
Total averías	360	1474	141
Tasa de averías (averías/unidad año)	0,0708	0,0313	0,058

Tabla 2.2. Estudio sobre fiabilidad en motores de inducción [IEE85].

VELOCIDAD rpm	POTENCIA HP	Nº FALLOS RECOGIDOS	UNIDADES AÑO	TASA DE FALLOS
0 – 720	201 - 500	7	137,92	0,0508
	501 - 5000	12	175,16	0,0685
721 – 1800	201 - 500	148	1922,43	0,0770
	501 - 5000	66	740,1	0,0892
3600	201 - 500	42	655,75	0,0640
	501 - 5000	16	358,66	0,0446

Tabla 2.3. Tasa de fallo según potencia. Industria Petroquímica, [THO97a].

POTENCIA (kW)	101-200	201-500	501-1000	>1000
Número de motores	44	163	69	80
Tamaño muestra (unidades año)	360	1271	448	351
Número de fallos	30	83	17	11
Tasa de fallo (fallos/unidades año)	0,083	0,065	0,038	0,031

Sólo encontramos datos sobre tasas de fallo para motores de potencias inferiores en el estudio realizado por Thorsen y Dalva en 1995. Para un total de 1504 motores, con potencias comprendidas entre 11 y 50 kW, obtienen una tasa de fallo de 0,0531 fallos/unidades año y en 362 motores de potencias entre 51 y 100 kW, la tasa de fallo calculada es de 0,0541 fallos/unidad año, es decir, prácticamente coincide con la anterior.

Capítulo 2: Motor de Inducción y Fallos característicos

La Tabla 2.1 también ofrece datos de tasa de fallos de acuerdo con la velocidad de giro del motor, agrupados por velocidades que corresponden a motores de uno, dos y tres pares de polos (obsérvese que la frecuencia nominal de alimentación en el ámbito en que se realizaron los trabajos es de 60 Hz). Estos resultados son, en parte, sorprendentes, pues muestran que la mayor incidencia de averías se produce en los motores de 721 a 1800 rpm, sector de la muestra en donde se ha recogido el mayor número de resultados.

Por lo que respecta a la causa de las averías, los estudios de la EPRI sólo consideran tres causas principales (véase la Tabla 2.4), siendo muy elevado el porcentaje correspondiente al epígrafe de “otras causas” (52,6%). Mucho más explícito es el estudio de la IEEE, que señala el mal mantenimiento como la principal causa de fallo (22,8%), seguido de los defectos de fabricación (20,3%) y de instalación y técnicas de arranque inapropiadas (12,5%). El mantenimiento inadecuado se eleva hasta un porcentaje del 25,2% cuando los datos se refieren a motores de inducción trabajando en ambientes de interior.

Tabla 2.4. Causa de las averías (sólo motores de inducción) [IEE85] y [EPR85].

	IEEE (1985)	EPRI (1985)
Defectos de fabricación	20,3	31,1
Funcionamiento/operaciones inadecuadas	9	10,2
Adaptación motor-carga (1)	4,9	-
Protección física o eléctrica inadecuada (2)	11,8	-
Utilización inadecuada (1) + (2)	16,7	6,1
Mantenimiento inadecuado	22,8	-
Instalación/prearranque incorrecta	15,9	-
Agentes externos	2,8	-
Otras	12,5	52,6
Total de averías considerado	246	1474

En cuanto a la distribución porcentual de los fallos por elementos de los motores, ambos estudios obtienen resultados similares (véase la Tabla 2.5), señalándose los rodamientos como el órgano principal de incidencia de fallos del motor (entre el 40 y el 50%), seguido por aislamiento estático y, finalmente, los fallos del sistema del rotor, paquete rotórico y eje. No obstante, debe indicarse que el porcentaje denominado como “otros” sigue siendo elevado y que la evaluación exacta del elemento en el que se ha iniciado la avería en muchos casos requiere el análisis de un experto, pues frecuentemente el desarrollo de ciertas averías oculta el verdadero origen del fallo. Además, no todos los

fallos son observables, por ejemplo, cuando la avería se inicia por roturas y agrietamientos en las barras de las jaulas, especialmente en jaulas de aluminio.

Tabla 2.5. Distribución porcentual de averías por órganos (motores de inducción) [IEE85] y [EPR85].

	IEEE (1985)	EPRI (1985)
Relacionadas con rodamientos	50	41
Relacionadas con el estator	24,7	36
Relacionadas con el rotor	8,9	9
Otras	16,4	14
Total averías consideradas	304	1052

2.2.2.3 Consideraciones sobre los estudios de fiabilidad en motores de inducción.

Los estudios sobre la fiabilidad de los motores eléctricos anteriormente analizados, ofrecen además, multitud de resultados adicionales atendiendo a las condiciones de funcionamiento del motor, el plan de mantenimiento del mismo, el entorno de trabajo, agentes desencadenantes y contribuidores a las averías, etc. No obstante, antes de utilizar sus resultados, bien sea para ejercicios de diseño, fabricación, mantenimiento o estudio, es necesario hacer sobre los mismos una serie de consideraciones, además de las ya realizadas, y que son consecuencia de las grandes variaciones que ha experimentado tanto la aplicación de los motores como sus condiciones de trabajo, durante el tiempo que ha transcurrido desde la realización de estos estudios hasta nuestros días. Entre ellas, se puede destacar [DUQ02b].

- Cambios en el diseño de los motores. Se ha producido una continua evolución en la fabricación de los motores, con la introducción de nuevos diseños y materiales, particularmente en el aislamiento del estator y sus técnicas de aplicación, en el diseño y fabricación de los rodamientos y en la grasa para la lubricación de los mismos.
- El motor de inducción es utilizado actualmente en todos los ámbitos industriales, incluso en aquellas aplicaciones donde se requiere control continuo de la velocidad, hasta hace poco tiempo reservada casi exclusivamente a los motores de corriente continua. Esto ha sido posible por la utilización del motor conjuntamente con convertidores o variadores de frecuencia, lo que origina, en estos casos, condiciones de funcionamiento distintas a las que tiene el motor cuando es alimentado desde fuentes sinusoidales. Esta situación se va extendiendo progresivamente hacia motores de potencias más reducidas [JAC99].

- Cada vez son más numerosos los motores fabricados para trabajos en aplicaciones especiales. No existen datos históricos de importancia del funcionamiento de estos motores y no se conocen estadísticas de su fiabilidad, aunque parece ser que las mismas pueden diferir notablemente de los resultados conocidos para otro tipo de motores.
- Introducción de los motores de elevado rendimiento que, por ejemplo, están mejor preparados ante los excesos de temperatura que los motores estándar, pues el volumen del material ha aumentado y las pérdidas que se originan son menores [BON97].

2.2.3 Causas de fallos en el motor de inducción.

Tal como se ha visto en el apartado anterior, aunque el motor de inducción es muy robusto y fiable, cualquiera de sus componentes no está exento de sufrir un fallo. En este apartado, se pretende mostrar de forma resumida cuáles son las principales causas de esos fallos. Para realizar este análisis, se ha decidido agrupar los fallos en tres grandes grupos, tal como suele ser práctica habitual:

- Fallos en el estator.
- Fallos en el rotor.
- Fallos en rodamientos y eje.

Durante el funcionamiento de la máquina, ésta se ve sometida a una serie de esfuerzos, de diferente naturaleza, que si superan un cierto umbral pueden derivar en un fallo, e incluso, no superando dicho umbral, la combinación simultánea de varios de estos esfuerzos puede resultar también en un fallo del motor [DUQ04a] [BON12] [BON92a]. Los diferentes umbrales que la máquina puede tolerar se fijan en la etapa de diseño del motor. Los criterios que se siguen en esta elección son técnicos y económicos. Por ejemplo, se estima cuál va a ser el calentamiento de la máquina, y en función del mismo se determina la clase de aislamiento. La práctica habitual es ser conservador y escoger la siguiente clase a la realmente necesaria, pero no una clase innecesariamente superior porque esto repercutiría en el coste final de la máquina.

Los defectos de fabricación y la mala elección de materiales para la construcción tienen un efecto negativo sobre los umbrales de fallo. La vida útil de la máquina, aunque su funcionamiento se ajuste a lo establecido por el fabricante, se verá reducida en gran

medida por la presencia de estos defectos de fabricación. Esto también ocurre si las condiciones de operación del motor no se ajustan a las recomendaciones del fabricante.

La incidencia de los fallos también se puede ver alterada por las prácticas de mantenimiento ejecutadas sobre el motor. Por ejemplo, un engrase periódico de los rodamientos o una adecuada limpieza de la máquina pueden alargar la vida útil de los diferentes componentes y reducir el impacto sobre la máquina de los diferentes esfuerzos que pueden causar un fallo prematuro.

En lo que se refiere al estator, hay que tener en cuenta que su bobinado trifásico está formado por un conjunto de bobinas, normalmente de cobre, con un aislamiento eléctrico que es el elemento más débil y susceptible de sufrir un fallo bajo la acción de diferentes esfuerzos, entre los que se puede citar:

- Esfuerzos térmicos: cualquier funcionamiento anormal del motor (variaciones de tensión, fases desequilibradas, sobrecargas) produce un incremento de la temperatura de la máquina. Si dicha temperatura supera el valor marcado por la clase térmica del aislamiento, se produce un proceso de envejecimiento del mismo por el cuál va perdiendo sus propiedades dieléctricas y puede derivar en un cortocircuito. Una incorrecta elección de la clase de servicio del motor o un deficiente funcionamiento del sistema de ventilación o refrigeración de la máquina también son causa de un gran estrés térmico que acaba dañando el aislamiento eléctrico.
- Esfuerzos eléctricos: diversos fenómenos de carácter eléctrico, como el efecto corona, el tracking y algunos transitorios de tensión pueden producir que el dieléctrico falle.
- Esfuerzos mecánicos: las bobinas alojadas en las ranuras del estator están sometidas a fuerzas oscilatorias al doble de la frecuencia de la red. Esto se traduce en un movimiento en dirección radial y longitudinal que puede dañar el aislamiento de la bobina por rozamiento, sobre todo si el apilamiento de las chapas es de baja calidad. Rozamientos o golpes producidos por el rotor también son causa de un fallo del bobinado del estator.
- Esfuerzos medioambientales: el aislamiento también puede sufrir por la presencia de humedad o de partículas procedentes del exterior de la máquina, que por rozamiento pueden dañarlo. Estas partículas también pueden ser

precursores de puntos calientes en el bobinado, al impedir la correcta transmisión térmica del calor hacia el exterior de la bobina.

El rotor de la máquina está sometido a los mismos esfuerzos que se han comentado para el estator. Sin embargo, en este caso los esfuerzos de origen térmico y mecánico se ven intensificados. El rotor sufre un mayor calentamiento que el estator debido a la dificultad para extraer el calor producido. Las fuerzas centrífugas son especialmente significativas al final de las barras y en las conexiones con el anillo de cortocircuito, particularmente durante los transitorios (arranque, parada y variaciones bruscas de carga). Los defectos de calidad en la fabricación de la jaula y la mala elección de los materiales intensifican el efecto negativo de estos esfuerzos. A continuación se comentan con más detalle algunos de estos aspectos [BON88] [DUQ04b]:

- Esfuerzo térmico: los periodos de funcionamiento transitorio que no se ajusten a la clase de servicio del motor producen un calentamiento excesivo del rotor. Además, el calentamiento del rotor no es homogéneo. Se producen desequilibrios térmicos porque la distribución de la corriente en las barras no es uniforme, por deficiencias de fabricación de la jaula y en la refrigeración de la misma. Por estas razones se produce una dilatación desigual de la jaula y del paquete magnético que se traduce en el desarrollo de tensiones y presiones sobre los finales de las barras y el anillo de cortocircuito.
- Esfuerzo magnético: el motor, debido a las tolerancias de fabricación, no presenta un rotor perfectamente centrado en el entrehierro, por lo que sufre de un cierto nivel de excentricidad. Aunque el entrehierro es muy pequeño, aparece una fuerza de origen magnético sobre el rotor que tiende a reducir la reluctancia del entrehierro en la zona donde es más estrecho.
- Esfuerzos dinámicos: están relacionados con el funcionamiento del motor cuando se producen pares superiores a los de diseño o el rotor está sometido a esfuerzos cíclicos que pueden provocar un fallo por fatiga.
- Esfuerzos ambientales: el rotor puede ser atacado principalmente por humedad y por agentes químicos que suponen un deterioro de la jaula. También habría que considerar la posible presencia de materiales extraños que puedan atascar los conductos de ventilación.

- Esfuerzos mecánicos: Sumados a los fallos asociados con los esfuerzos mencionados previamente, hay otra amplia categoría de fallos que pueden ser agrupados bajo el encabezado general de fallos mecánicos [SAC93]. Algunos de los más comunes incluyen los siguientes: porosidad de la fundición, laminación suelta, piezas fatigadas o rotas, pérdida del entrehierro, eje del rotor torcido, fallos de los cojinetes, defecto de alineación, materiales incorrectos y resonancia de los dientes.

Los rodamientos tienen un tiempo de vida finito debido a la fatiga del material y que es especificado por los fabricantes y definido por diversos términos como: duración nominal, promedio, L10, etc. [DUQ04c] [BON92b] [BON93]. Son causas comunes de averías las siguientes:

- Deficiente montaje.
- Carga excesiva, en estado estacionario o dinámico.
- Lubricación inadecuada, insuficiente o excesiva.
- Contaminación externa.
- Diseño erróneo (tamaño incorrecto).
- Exposición a vibración cuando el motor está parado.
- Paso de corriente eléctrica.

Las causas más frecuentes de fallos en el eje son las debidas a corrosión, fatiga, fracturas y sobrecargas [BON98] [BON99] [BON00]. Para los motores eléctricos, el fallo por fatiga puede llegar a alcanzar el 90% del total de fallos en el eje, particularmente si los mismos no están diseñados, fabricados o usados de acuerdo con la aplicación requerida.

2.3. Análisis de la corriente del estator.

2.3.1 Efecto producido por las asimetrías del circuito del rotor sobre el campo en el entrehierro

De los métodos que muestran la influencia de una barra rota sobre el funcionamiento del motor, el análisis realizado en [DEL82], es el que ofrece una explicación más sencilla [DUQ05]. Si consideramos la distribución real de corrientes que circula por la jaula del rotor con una barra rota como la superposición de dos términos, a) la corriente que

circularía por la jaula sin avería y b) una corriente originada por una fuente de corriente que, situada en la barra rota, suministra una corriente de igual valor y sentido contrario a la corriente que circula por esta misma barra cuando no hay avería. De esta forma, la superposición de las corrientes debidas a ambos términos dará por resultado una corriente nula por la barra rota.

La Fig. 2.3 muestra la situación en que sólo se considera el efecto de la corriente inyectada por la fuente de corriente adicional I_{bi} (segundo término de corrientes). El resto del rotor es modelizado como un conjunto de mallas de igual impedancia, distribuidas de forma simétrica alrededor de la barra rota. Cada malla incluye las resistencias y reactancias de dispersión de las barras (R_b y X_b) y de la parte del anillo de cortocircuito situado entre barras (R_a y X_a) y la reactancia X_g debida al flujo producido por la corriente de malla del rotor que atraviesa el entrehierro y cierra el camino vía el hierro del estator [DUQ05].

Para determinar las corrientes que circulan por las mallas del circuito de la Fig. 2.3, se establece un factor de amortiguamiento complejo FA , el cual determina la diferencia en magnitud y ángulo de fase entre las corrientes en dos mallas adyacentes. Así la corriente en la malla i , que corresponde a la barra rota, viene dada por:

$$I_{ij} = I_{ri} FA^{i-1} \quad (2.1)$$

donde:

$$FA = (1 + A_d) \pm \sqrt{(1 + A_d)^2 - 1} \quad (2.2)$$

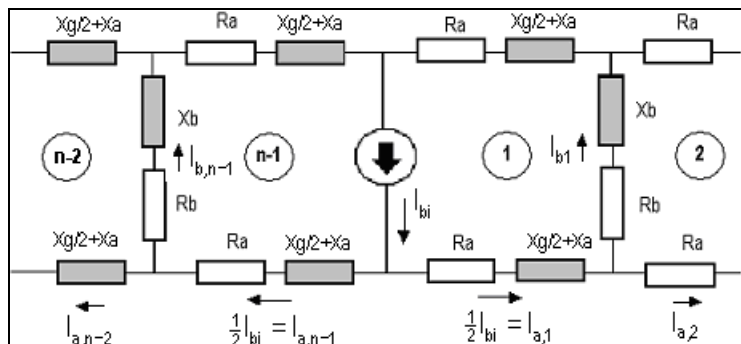


Figura 2.3 Circuito equivalente del rotor, la fuente I_{bi} representa a la barra rota [DUQ05].

Siendo A_d una variable compleja dependiente del deslizamiento, que aglutina a los parámetros característicos del circuito y cuyo valor es:

$$A_d = \frac{R_a + js(X_a + \frac{1}{2}H_g)}{R_b + jsX_b} \quad (2.3)$$

La corriente en la barra rota produce dos campos idénticos, que circulan desde la barra a través del entrehierro, en direcciones opuestas, con un amortiguamiento determinado por FA . Puesto que las corrientes deben decrecer cuando nos movemos desde la barra rota, sólo la solución de (2.2) donde $|FA| < 1$ tiene sentido físico.

La densidad de flujo producida por la corriente adicional en la barra rota está dada por:

$$B_{\partial 1} = \frac{\mu_0 I_{r1}}{I_{re}} \quad (2.4)$$

Siendo I_{re} la longitud radial del entrehierro.

Puesto que hay una diferencia constante FA , entre la corriente entre barras adyacentes, la densidad de flujo originado por la corriente en la malla i , será:

$$B_{\partial i} = B_{\partial 1} FA^{i-1} \quad (2.5)$$

El flujo total producido será la suma de los flujos debidos a cada malla.

El campo magnético causado por la rotura de una barra presenta las siguientes características:

- Es un campo alternativo de eje fijo.
- Es de naturaleza escalonada, debido al número limitado de barras.
- Presenta un par de polos localizados a ambos lados de la avería.

Dicho campo se puede descomponer, por lo tanto, mediante un desarrollo en serie de Fourier, en una suma de campos senoidales. Si a cada uno de estos campos se aplica el teorema de Leblanc, se obtendrá una pareja de campos que giran respecto al rotor en sentidos contrarios a la velocidad de deslizamiento.

2.3.2 Armónicos originados por la rotura de una barra del rotor

De la ecuación (2.4) puede deducirse que cuando nos movemos a partir de la barra rota, hacia barras adyacentes, los campos producidos por las corrientes adicionales cambiarán en una forma escalonada que determina el factor de amortiguamiento FA . La forma escalonada de la distribución de campo podrá descomponerse en una serie de armónicos

espaciales en el entrehierro, de los cuales el fundamental tendrá siempre dos polos. Debido a la estructura trifásica simétrica de los devanados del motor, sólo los armónicos de la corriente del rotor de orden: $j = p, 5p, 7p, 11p, 13p, \dots$, pueden tener influencia sobre el espectro de la corriente del estator [DUQ05].

Por otra parte, al estar los devanados del estator alojados en ranuras, la corriente que circula por ellos origina campos de naturaleza escalonada. Esto dará por resultado nuevos armónicos espaciales en el entrehierro, cada uno de los cuales inducirá en el rotor una corriente de diferente frecuencia y, en el caso de que exista una o más barras rotas en el rotor para cada frecuencia inducida tenemos una corriente “inyectada” sobre la barra rota, con su propio factor de amortiguación. De acuerdo con [DEL82], las tensiones que son inducidas en el estator como consecuencia de los campos originados por estas corrientes debidas a la barra rota contendrán frecuencias que pueden ser determinadas mediante análisis de Fourier y que pueden ser calculadas a partir de la siguiente ecuación [DUQ05]:

$$f = f_1 \left[\frac{j}{p} (1-s) \mp s \right] \quad (2.6)$$

En donde el signo positivo corresponde a las tensiones inducidas por las ondas de campo que viajan en la misma dirección que el rotor y el signo negativo a las que viajan en sentido contrario.

La influencia de la componente debida al armónico fundamental ($j = p$) es predominante. Para este caso, se obtiene (2.7) para la onda de campo que viaja en el mismo sentido que el rotor, y (2.8) para la onda de campo que gira en sentido contrario.

$$f = f_1 \quad (2.7)$$

$$f = f_1(1-2s) \quad (2.8)$$

Las tensiones inducidas en los devanados del estator dan lugar a corrientes correspondientes de igual frecuencia y, teniendo en cuenta que excepto para los primeros armónicos de f_1 , la reactancia del estator es muy elevada, la corriente medida a estas frecuencias es muy pequeña en relación con la corriente que corresponde a los armónicos de bajo orden [DUQ05].

Cabe resaltar que no solo la distancia entre el armónico principal y el armónico inducido por la barra rota aumenta con el deslizamiento, sino que también la amplitud de dicho

armónico de fallo crece con la carga del motor (deslizamiento) [GAR12]. La Fig. 2.4 presenta el espectro de la corriente de un motor con media barra rota, en vacío a la derecha y con máxima carga a la izquierda. Se puede apreciar a simple vista el incremento en la magnitud del armónico de fallo.




Figura 2.4 Espectro de la corriente alrededor del 1^{er} armónico para un motor con media barra rota en vacío, derecha y a plena carga, izquierda.

2.3.3 Armónicos de la corriente del estator originados por las pulsaciones del par y de la velocidad

La variación cíclica de la corriente produce una oscilación del par al doble de la frecuencia de deslizamiento. Esto origina una variación no despreciable de la velocidad, que depende de la inercia del sistema. Como consecuencia se produce una reducción en la magnitud de la componente de la corriente de frecuencia $(1-2s)f_1$ y la aparición de una nueva banda lateral a $(1+2s)f_1$. Este proceso, cuya secuencia se esquematiza en la Fig. 2.5, continúa hasta su total amortiguación.

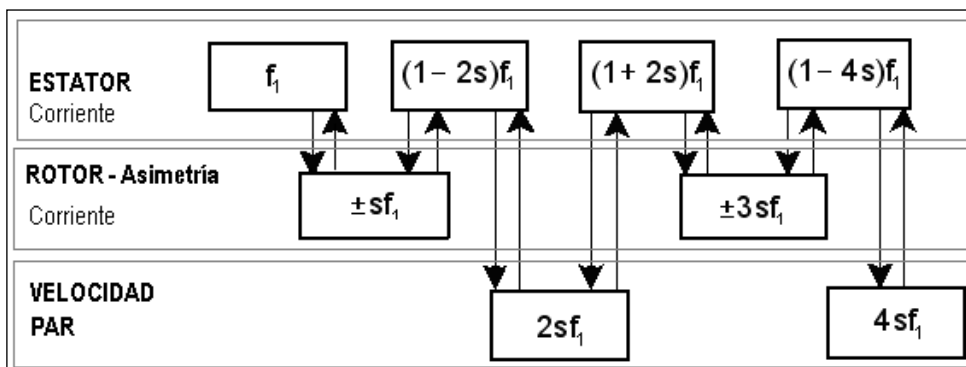


Figura 2.5 Secuencia de aparición de nuevos armónicos de corriente [DUQ05].

Supongamos una máquina de inducción trifásica, en estado estacionario, con distribución sinusoidal de la fuerza magnetomotriz y en la que hay presente una asimetría en el rotor, originada, por ejemplo, por una barra rota. En este caso el proceso

que sigue a la existencia de una asimetría en el rotor, tal como una barra rota o fisurada, agrietamiento de la jaula, fisuras en el anillo de cortocircuito, uniones entre barras y anillo en mal estado, etc., es el que sigue [DUQ05]:

- La asimetría del rotor origina una componente I_1 de la corriente del estator a frecuencia $(1-2s)f_1$.
- Como consecuencia de I_1 , aparece una componente de par que da lugar a que la velocidad oscile con frecuencia $2sf_1$, con amplitud que depende de las condiciones de funcionamiento y de la inercia del sistema y que induce unas fuerzas electromotrices en el estator, que dan lugar a una corriente de reacción I'_1 a frecuencia $(1-2s)f_1$, y a una nueva componente I_2 , de frecuencia $(1+2s)f_1$. Estas componentes tienen igual amplitud.
- El armónico resultante de frecuencia $(1-2s)f_1$ es la diferencia entre I_1 y de su reacción I'_1 , esto es: $I_2 = I_1 - I'_1$.
- La corriente del estator I_2 da lugar a nuevas corrientes en el rotor de frecuencia $3sf_1$. Estas corrientes originan nuevos campos rotativos de secuencia positiva y negativa, que inducen las corrientes del estator I'_2 e I_3 , de frecuencias $(1+2s)f_1$ y $(1-4s)f_1$, respectivamente.
- La corriente I_3 da lugar a una componente de par T_2 , de frecuencia $4sf_1$ y nuevas pulsaciones de velocidad de igual frecuencia.
- Las pulsaciones de velocidad originan nuevas componentes de corriente del estator I'_3 e I_4 , a frecuencias $(1-4s)f_1$ y $(1+4s)f_1$, respectivamente.

El proceso continúa indefinidamente hasta la atenuación de las variables en juego, esto es, del par, velocidad y corriente del estator, lo que dependerá de las características del motor y de la inercia conjunta del motor y de la carga. La expresión general de las frecuencias de las corrientes del estator adopta la forma:

$$(1 \pm 2ns)f_1 \quad (2.9)$$

donde $n = 1, 2, 3, \dots$

El deslizamiento s es la diferencia entre la velocidad del campo magnético fundamental y el valor medio de la velocidad del rotor, bajo la suposición de que la influencia de la oscilación de velocidad es despreciable con respecto al valor del deslizamiento obtenido.

Por lo que respecta al valor de la amplitud de las pulsaciones del par y de la velocidad y de la amplitud de las componentes de la corriente del estator inducidas, de forma general se incrementan conforme progresa la magnitud del fallo.

2.4. Procesamiento de señal de la corriente del estator para la obtención de patrones.

La señal de la corriente obtenida directamente del sensor no ofrece ninguna información útil para la detección de fallos, pues a simple vista (en un osciloscopio) es imposible diferenciar la corriente de un motor sano de uno con avería. Para que esta señal pueda ser empleada para el diagnóstico de fallos como barras rotas, primero debe ser procesada para poder extraer de ella ciertas características o variables indicativas de fallo que sí pueden ser utilizadas para el diagnóstico. Existen diversas técnicas para el procesamiento de la señal. A continuación se presenta una introducción a las técnicas que se emplearán en esta tesis, que pueden clasificarse en procesamiento en dominio del tiempo y en dominio de la frecuencia.

2.4.1. Dominio del tiempo

El análisis en el dominio del tiempo existe desde la aparición del osciloscopio. Permite establecer características básicas de las formas de onda [CLI12].

Diversos autores han propuesto la utilización de características estadísticas obtenidas directamente de la señal en el dominio del tiempo, tanto de vibración [PAY02], [ZAE12] como de corriente [VAN09], [GHA10]. Algunas de estas características tienen una interpretación física o geométrica clara y otras se poseen un poder discriminante entre tipos de fallos que las hacen útiles para el diagnóstico pero no poseen una interpretación geométrica o física que facilite su visualización.

A continuación se explican algunos estadísticos, cuya interpretación física o geométrica resulta sencilla.

Coefficiente de asimetría o Skewness: Una distribución es simétrica cuando a ambos lados de la media existen la misma cantidad de valores, equidistantes dos a dos de la media, y con la misma frecuencia. En caso contrario, decimos que la distribución es asimétrica, y entonces puede ser de dos tipos [NUÑ05], como se muestra en la Fig. 2.6.




Figura 2.6 a) Curva asimétrica a la izquierda, b) Curva asimétrica a la derecha [EXP13].

Dependiendo del valor del coeficiente de asimetría (skew) la distribución puede ser:

- a) Si $skew > 0$, la distribución es asimétrica positiva o a la derecha.
- b) Si $skew = 0$, la distribución es simétrica.
- c) Si $skew < 0$, la distribución es asimétrica negativa o a la izquierda

El Coeficiente de Curtosis: pretende comparar la curva de una distribución con la curva de la variable Normal, en función de la cantidad de valores extremos de la distribución.

Una distribución es Mesocúrtica si la distribución de sus datos es la misma que la de la variable Normal. En ese caso, su coeficiente de curtosis es 3. La distribución es Leptocúrtica si está más apuntada que la Normal. En ese caso, su coeficiente de Curtosis vale más que 3. Si la distribución está menos apuntada que la Normal, entonces es Platicúrtica, y su coeficiente de Curtosis vale menos que 3 [NUÑ05].




Figura 2.7. Clasificación de una distribución de datos de acuerdo a su coeficiente de curtosis [EXP13].

El factor de cresta para una onda sinodal es siempre $\sqrt{2} = 1,41\dots$. Un factor de cresta muy elevado implica sobre-intensidades puntuales importantes.

El factor de forma de una onda es la relación entre el valor eficaz y el valor medio, con lo que se obtiene una forma aproximada de la función. Tiene siempre un valor mayor o

igual a 1. Si el factor de forma es pequeño, indica que la onda tiene poco nivel de alterna mientras que si es muy grande la onda tiene poca componente de continua y mucha de alterna [SEG02].

2.4.2. Dominio de la frecuencia: FFT y Hilbert

La técnica del análisis espectral de la corriente, de la vibración, del flujo o cualquier otra magnitud continua, está basada en el registro de estas señales en el tiempo y su transformación al dominio de la frecuencia.

2.4.2.1 La Transformada de Fourier

Las transformaciones de una señal entre el dominio del tiempo y de la frecuencia y sus inversas, se basan en la Transformada de Fourier y la Transformada Inversa de Fourier, definidas como [LEI09]:

$$X(f) = \int_{-\infty}^{+\infty} x(t) \cdot e^{-j2\pi ft} dt \quad (2.10)$$

$$x(t) = \int_{-\infty}^{+\infty} X(f) \cdot e^{j2\pi ft} df \quad (2.11)$$

donde:

- $x(t)$: representación en el tiempo de la señal x .
- $X(f)$: representación en la frecuencia de la señal x .
- $j = \sqrt{-1}$

Un aspecto importante que debe de considerarse cuando se aplica la Transformada de Fourier es la estacionariedad de la señal $x(t)$. De manera sencilla, podemos definir que una señal, $x(t)$, es estacionaria si sus componentes frecuenciales existen para toda t en que $x(t)$ este definida. Por el contrario, una señal no es estacionaria si algunas de sus componentes frecuenciales solamente existen en ciertos intervalos de tiempo [LEI09].

En la Fig. 2.8 se observa que en los primeros 0,3 segundos de la señal la componente de frecuencia es de 10 Hz, en los siguientes 0,3 s la componente es de 25 Hz, y finalmente, en los últimos 0,3 segundos existe una componente de 50 Hz. El espectro de la señal muestra que estas tres frecuencias (10, 25 y 50 Hz) son las componentes principales de la señal. Los picos de menor magnitud que se presentan entre las componentes

principales se producen por los cambios de frecuencia cada 0,3 s. Si la señal se hubiera formado con la suma de las tres sinusoidales: $\text{sen}(2\pi 10t) + \text{sen}(2\pi 25t) + \text{sen}(2\pi 50t)$, es decir una señal estacionaria, el espectro obtenido con la Transformada de Fourier hubiera sido similar al mostrado en la Fig. 2.8




Figura 2.8. Señal no estacionaria y su comportamiento en el dominio de la frecuencia [LEI09].

Densidad espectral de potencia: La Densidad Espectral de Potencia PSD (*Power Spectral Density*), $|X(f)|^2$, se mide en V^2/Hz . Contiene información relacionada con la Distribución en Potencia de la señal $x(t)$ en el dominio de la Frecuencia. Su aplicación principal es en el análisis espectral de señales aleatorias o señales periódicas contaminadas con ruido. La Densidad Espectral de Potencia se determina mediante la siguiente expresión:

$$|X(f)|^2 = X(f) \cdot X^*(f) \quad (2.12)$$

La Densidad Espectral de Potencia no muestra el comportamiento de la fase.

La transformada discreta de Fourier: En la ecuación (2.10) se define a la Transformada de Fourier como una integral de $-\infty$ a $+\infty$. Esto implica operar con una formulación analítica de la señal y considerar un periodo de muestreo infinito, ninguna de estos dos requerimientos se cumple en la práctica pues se trabaja con una señal muestreada de la corriente y no se dispone de la formulación analítica de la misma y el periodo de muestreo es finito. Al considerar la señal muestreada la Transformada de Fourier se define como [DUQ05]:

$$X(m\Delta f) = \int_{-\infty}^{+\infty} x(t) \cdot e^{-j2\pi\Delta f t} dt \quad (2.13)$$

donde:

- $m = 0, \pm 1, \pm 2, \dots$
- Δf : espacio entre líneas de frecuencia.

Además, los métodos de integración numérica convierten el cálculo de la integral en una serie de sumas, con lo que tenemos:

$$X_x(m\Delta f) \approx \Delta t \sum_{n=-\infty}^{+\infty} x(n\Delta t).e^{-j2\pi m\Delta f\Delta t} \quad (2.14)$$

siendo:

Δt : intervalo de tiempo entre dos muestras consecutivas.

Por último, debemos considerar el sumatorio a un valor finito, con lo que nos queda:

$$X_x(m\Delta f) \approx \Delta t \sum_{n=0}^{N-1} x(n\Delta t).e^{-j2\pi m\Delta f\Delta t} \quad (2.15)$$

La transformada rápida de Fourier: El cálculo digital de la Transformada de Fourier es un proceso largo debido al elevado número de operaciones matemáticas a realizar. La Transformada Rápida de Fourier (FFT) es un algoritmo desarrollado en 1965 por Cooley y Tukey de la Universidad de Columbia, que consigue calcular el resultado de la Transformada de Fourier con mayor rapidez y eficiencia a partir de escoger un número de muestras N que sea potencia de dos, para lo cual aprovecha ciertas propiedades de simetría.

Propiedades de la transformada rápida de Fourier:

La frecuencia más baja que vamos a conseguir con un analizador FFT va a estar basada en la longitud del registro en el tiempo. Si el periodo de la señal de entrada es mayor que el registro en el tiempo, no podemos determinar completamente este periodo. Así, en principio, la frecuencia inferior del espectro debe ocurrir a la inversa de la longitud del periodo de muestreo, PM [DUQ05]:

$$f_{\min} = \frac{1}{PM} \quad (2.16)$$

La resolución del espectro es $1/PM$, esta es la menor distancia a la que dos componentes del espectro pueden ser separados. Por ejemplo, si queremos una resolución de 1 Hz, el tiempo de grabación del registro es 1 s y si queremos una resolución de 0,1 Hz, la duración de la grabación será 10 s.

Inmediatamente obtenemos la mayor frecuencia del espectro, sin más que multiplicar por el número de líneas de frecuencia:

$$f_{\max} = \frac{N}{2} \frac{1}{PM} \quad (2.17)$$

Donde N es el número de muestras por segundo (debe ser múltiplo de 2 para la FFT).

Efecto ventana: Un requisito para implantar la FFT es que la señal sea periódica en el tiempo de registro. Para conseguir esto, la señal debe estar cerca de cero al principio y final del periodo de muestreo. En la práctica esto se consigue multiplicando la señal por una función llamada “ventana” o “ponderación”.

La ventana Hanning es la más comúnmente utilizada. Su expresión matemática es la de un coseno más una unidad para que el resultado sea siempre positivo. Los valores de la función muestreada se multiplican por la función Hanning, con lo que se fuerza a que los extremos de la grabación se pongan a cero [DUQ05].

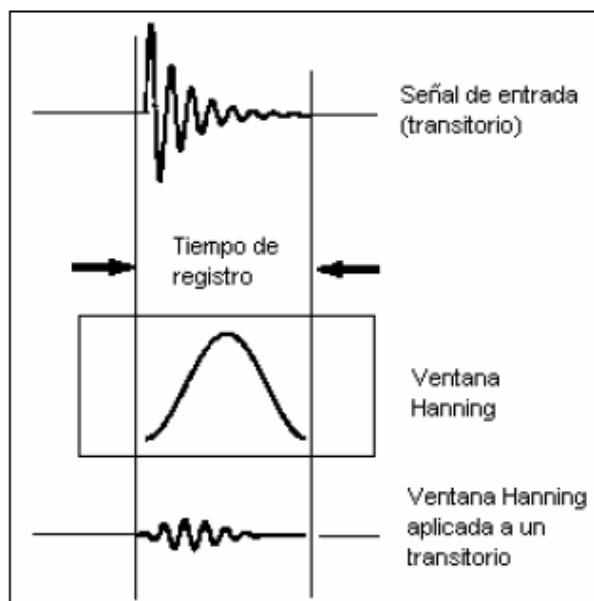


Figura 2.9. Error al aplicar la ventana Hanning a una señal transitoria [DUQ05].

La ventana Hanning, además de hacer nulos los extremos de la muestra en el tiempo, agrega cierta distorsión a la señal analizada, bajo la forma de modulación de amplitud. La modulación de amplitud en una forma de onda origina bandas laterales en su espectro que provocan la reducción de la resolución de frecuencia. El efecto es que las líneas del espectro se hacen más anchas.

La amplitud medida de la señal ponderada por la ventana Hanning también es incorrecta, ya que en esencia se elimina la mitad de la señal en el proceso de ponderado. Esto puede corregirse fácilmente multiplicando los niveles del espectro por dos. Este proceso supone que la amplitud de la señal es constante en todo el intervalo de muestreo. Si no es así, como en el caso de una señal transitoria, el cálculo de la amplitud tendrá un cierto error [DUQ05].

2.4.2.2 La Transformada de Hilbert

La Transformada de Hilbert es una técnica de análisis de señales utilizada en diversas áreas, como el procesamiento de datos geofísicos, detección de fallos en motores de inducción o la transmisión de señales entre otros [PUC09].

Matemáticamente se define como la convolución con la función $1/t$, tal como se expresa en la ecuación (2.18):

$$HT(x(t)) = y(t) = \frac{1}{\pi t} x(t) = \frac{1}{\pi} \int_{-\infty}^{+\infty} \frac{x(\tau)}{t - \tau} d\tau \quad (2.18)$$

Nótese que la función de convolución es singular en $t=\tau$. Por lo tanto la integral en (2.18) es impropia en el sentido del valor principal de Cauchy [LIU12]:

$$HT(x(t)) = y(t) = \frac{1}{\pi} \int_{-\infty}^{+\infty} \frac{x(\tau)}{t - \tau} d\tau = \frac{1}{\pi} \lim_{\varepsilon \rightarrow 0} \left(\int_{-\infty}^{t-\varepsilon} + \int_{t+\varepsilon}^{+\infty} \right) x(\tau) \cdot h(t - \tau) d\tau \quad (2.19)$$

Uniendo la señal $x(t)$ y su Transformada de Hilbert se crea la denominada señal analítica $\bar{x}(t)$ [PUC09]:

$$\bar{x}(t) = x(t) + jy(t) = a(t)e^{j\theta(t)} \quad (2.20)$$

donde:

$$a(t) = \sqrt{x^2(t) + y^2(t)} \quad \text{y} \quad \theta(t) = \arctan\left(\frac{y(t)}{x(t)}\right) \quad (2.21)$$

En (2.20) y (2.21), $a(t)$ es la amplitud instantánea de $\bar{x}(t)$, la cual refleja cómo la energía de $x(t)$ varía con el tiempo y $\theta(t)$ es la fase instantánea de $\bar{x}(t)$.

Las tres propiedades de la Transformada de Hilbert y de la Señal Analítica más importantes para el análisis de la señal de corriente son [PUC09]:

1) La transformada de Hilbert de una función trigonométrica es la misma función desfasada 90° . Así, el espectro de una Transformada de Hilbert tiene los mismos componentes de amplitud y frecuencia que la señal original, pero la fase de cada componente de frecuencia está desfasada 90° .

2) La señal analítica retiene los componentes de frecuencia positiva, mientras elimina los de frecuencia negativa y dobla el componente de corriente continua.

3) Todas las bajas frecuencias de la señal original están en la amplitud de la Señal Analítica $a(t)$, mientras que las altas frecuencias están en la fase $\theta(t)$. La fase de la corriente en una máquina ideal es puramente senoidal [PUC09]:

$$i(t) = I_m \cos(\omega t) = I_m \cos(2\pi f t) = I_m \left(\frac{e^{j\omega t} + e^{-j\omega t}}{2} \right) = \frac{I_m}{2} e^{j\omega t} + \frac{I_m}{2} e^{-j\omega t} \quad (2.22)$$

La Transformada de Fourier de $i(t)$ mostrará dos componentes, a las frecuencias f y $-f$.

La señal analítica correspondiente a $i(t)$ es:

$$\bar{i}(t) = i(t) + jHT(i(t)) = I_m (\cos(\omega t) + j\text{sen}(\omega t)) \quad (2.23)$$

Recordando la función $\text{sen}(\omega t)$ en función de exponentes complejos:

$$\text{sen}(\omega t) = \left(\frac{e^{j\omega t} - e^{-j\omega t}}{2j} \right) \quad (2.24)$$

Combinando (2.22), (2.23) y (2.24) obtenemos:

$$\bar{i}(t) = I_m e^{j\omega t} \quad (2.25)$$

La Transformada de Fourier de (2.25) mostrará un solo componente correspondiente a la frecuencia positiva $f = \omega / (2\pi)$, y de doble amplitud respecto al espectro de la señal original.

Si consideramos una máquina con averías, se presentan perturbaciones periódicas, como las producidas por una barra rota. La amplitud de la corriente en cada fase es modulada con la frecuencia característica de fallo:

$$i_b(t) = i(t)[1 + \beta \cos(\omega_0 t)] \quad (2.26)$$

Donde β denota la profundidad de modulación (índice de modulación) y $\omega_0 = 2\pi f_0$.

Sustituyendo (2.26) en (2.23) obtenemos:

$$i_b(t) = I_m \cos(\varpi t) [1 + \beta \cos(\varpi_0 t)] \quad (2.27)$$

Después de realizar la multiplicación de cosenos llegamos a:

$$i_b(t) = I_m \cos(\varpi t) + \frac{\beta I_m}{2} [\cos((\varpi - \varpi_0)t) + \cos((\varpi + \varpi_0)t)] \quad (2.28)$$

La expresión (2.28) muestra la presencia de las frecuencias de las dos bandas laterales características del fallo. La Transformada de Hilbert de esta corriente se construye simplemente cambiando la función coseno por seno:

$$HT(i_b(t)) = I_m \text{sen}(\varpi t) + \frac{\beta I_m}{2} [\text{sen}((\varpi - \varpi_0)t) + \text{sen}((\varpi + \varpi_0)t)] \quad (2.29)$$

que puede ser reescrito como:

$$HT(i_b(t)) = I_m \text{sen}(\varpi t) + [1 + \beta \cos(\varpi_0 t)] \quad (2.30)$$

La Señal Analítica se construye combinando (2.26) como parte real y (2.30) como parte imaginaria:

$$\vec{i}_b(t) = [1 + \beta \cos(\varpi_0 t)] I_m (\cos(\varpi t) + j \text{sen}(\varpi t)) = [1 + \beta \cos(\varpi_0 t)] I_m e^{j \varpi t} \quad (2.31)$$

El módulo de la Señal Analítica muestra una pulsación a la frecuencia característica de fallo de la máquina. La ecuación (2.31) puede ser aplicada no solo al caso de barras rotas $\omega_0=2\pi(2sf_1)$, sino también a otros fallos, tales como la combinación de excentricidad estática y dinámica $\omega_0=2\pi f_r$, donde f_r es la frecuencia de rotación [PUC09].

3 Estado del arte del mantenimiento y diagnóstico en motores de inducción

3.1 Introducción

La monitorización de estado es el proceso de vigilar un sistema estudiando un grupo determinado de parámetros de tal forma que un cambio significativo en dichos parámetros esté relacionado con el desarrollo de un tipo determinado de fallo [MAR12].

Según Marwala [MAR12], la teoría generalizada de la monitorización de estado se ilustra en la Fig. 3.1, con un esquema por bloques. Esta figura muestra en el primer bloque que hay un dispositivo de adquisición de datos, cuya función principal es la de medir una señal o señales del sistema o máquina. Ejemplos de estos dispositivos de medición son: termómetros, acelerómetros, o galgas extensométricas. El segundo bloque en la Fig. 3.1 contiene el dispositivo de análisis de datos, cuya función es la de analizar los datos adquiridos por el dispositivo anterior. Ejemplos de este tipo de métodos son wavelets, la transformada de Fourier, la distribución Wigner-Ville, la transformada de Hilbert, entre otros. El tercer bloque representa la técnica de selección y cuantificación de características relevantes para la detección de fallos; en algunos casos se utilizan características señaladas por estudios físicos del sistema. Por ejemplo, en el caso de barras rotas en motores de inducción se sabe que aumentan unas bandas en el espectro de la corriente estatórica ubicadas a unas frecuencias específicas que dependen del deslizamiento y la frecuencia fundamental. Para seleccionar qué características utilizar en el proceso de monitorización se pueden aplicar métodos como el análisis de componentes principales o el análisis de componentes independientes. El dispositivo de toma de decisiones, que figura en el cuarto bloque, es una infraestructura o metodología, cuya principal función es la de interpretar las características seleccionadas e inferir con ellas el estado del sistema o máquina. Este tipo de metodología incluye técnicas estadísticas como regresión logística, análisis discriminante o árboles de decisión, métodos de inteligencia artificial tales como redes neuronales, máquinas de vectores de soporte, lógica difusa, sistemas expertos o combinaciones de estas técnicas. El resultado del proceso es el diagnóstico de la condición del sistema o proceso.

Por ejemplo, implementando los procedimientos de la Fig. 3.1, Gunnal *et al.* [GUN09] usaron la corriente del motor como dato de entrada, análisis de filtro atenuador (notch-filtering), y utilizaron clasificadores estadísticos como dispositivo de toma de decisión.

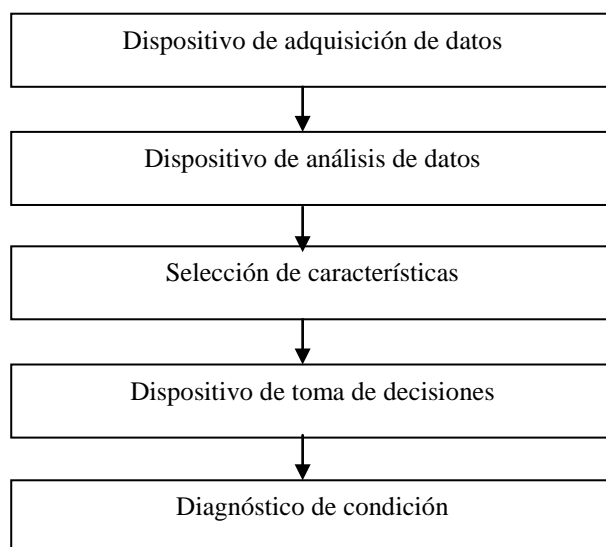


Figura 3.1. Esquema de la teoría generalizada de la monitorización de estado [MAR12].

Loutas *et al.* [LOU11] utilizaron vibraciones, residuos de aceite y emisiones sonoras como dispositivos de adquisición y análisis de datos, análisis de componentes principales como selector de características y reglas heurísticas como dispositivo de toma de decisiones para monitorizar la condición de una máquina rotativa.

Garcia *et al.* [GAR11b] usaron la corriente estatórica como dato de entrada y la transformada rápida de Fourier como técnica de análisis, con control de calidad robusto basado en gráficos de control multivariantes como un dispositivo de toma de decisiones, para implementar una metodología de detección temprana de barras rotas del rotor en los motores de inducción.

Los dispositivos de adquisición de datos se pueden clasificar de acuerdo al tipo de efecto físico que miden, como pueden ser las emisiones acústicas, corriente estatórica, campo electromagnético, tensión, temperatura, etc. Debido a esto se expondrán a continuación los tipos de dispositivos de adquisición de datos más utilizados en el diagnóstico de máquinas eléctricas, clasificados según el efecto físico que miden. Seguidamente se explicaran las técnicas de análisis de datos y selección de características más empleadas en la monitorización de condición de máquinas eléctricas para finalmente explicar las metodologías de toma de decisión más populares actualmente, con una sección especial para la detección de barras rotas con redes neuronales considerando que esta tesis propone una aplicación de este tipo.

3.2 Dispositivos de adquisición de datos de acuerdo al tipo de efecto medido

El primer paso para el diagnóstico de fallos en máquinas eléctricas es definir qué clase de efecto físico de la máquina se desea utilizar como dato de entrada, esto es, definir qué dispositivo de adquisición de datos se empleará. Las técnicas de diagnóstico de máquinas eléctricas pueden clasificarse, en función del efecto físico que mide el dispositivo de adquisición de datos, en las siguientes categorías [REZ11]:

- Emisiones acústicas
- Par en el entrehierro
- Corriente en el estator
- Monitorización del campo electromagnético
- Tensión inducida
- Velocidad angular instantánea
- Potencia instantánea
- Análisis circuital del motor
- Ensayos de sobretensión (Surge tests)
- Vibraciones
- Tensión
- Temperatura
- Análisis de gases.

A continuación, se analizan brevemente cada una de ellas.

3.2.1 Emisiones acústicas:

Las emisiones acústicas son el producto de la rápida liberación de la energía de deformación causada por una alteración estructural en un material sólido bajo estrés [TAN99]. La medición del espectro acústico de motores de inducción es utilizada como una técnica de monitorización convencional. Este método es especialmente utilizado para la detección de fallas en rodamientos, pero también ha sido aplicado al diagnóstico de fallos en el rotor [REZ11]. La relación entre la excentricidad del rotor y las emisiones acústicas ha sido estudiada por Ellison y Yang [ELL71]. Li y Mechefske mostraron que la diferencia entre las bandas laterales de un motor sano y uno con barras rotas no es tan claramente diferenciable en el espectro acústico como lo es en el espectro

de vibraciones y de corrientes [LI06]. El análisis acústico depende de varios factores que influyen en su fiabilidad [LI06], [GAY95], [VER03], [VER96]. El espectro acústico depende además de la posición de la medición, del tamaño, geometría estructural del motor, etc. Además, la efectividad de este método se ve influida negativamente por el ruido de otras máquinas operando en la vecindad.

3.2.2 Par en el entrehierro

El par en el entrehierro es producto del flujo inducido y de las corrientes del motor. Casi todas los fallos en motores de inducción causan variaciones en frecuencias específicas del par en el entrehierro. Hsu *et al.* [HSU92] demostraron que analizando la forma del par en el entrehierro se puede distinguir si el fallo es causado por barras rotas o por desequilibrio en el bobinado del estator. Se ha probado que la aparición de una banda del doble del deslizamiento en el espectro del par en el entrehierro está relacionada con fallas en el rotor, mientras que las fallas en el estator están relacionadas con frecuencias del doble de la fundamental. Sin embargo, la principal limitación de la medición del par en el entrehierro es que no puede ser realizada en forma directa y precisa. Las pulsaciones del par de un MI medidas con un sensor acoplado al eje o el soporte del estator son diferentes al verdadero valor del par en el entrehierro. Esto se debe a que el rotor, eje, carcasa del MI así como su carga mecánica constituyen un sistema con su propia frecuencia natural. Además, la mayoría de los sensores de par tienen su propia frecuencia natural así como su ancho de banda [HSU92], [HSU95].

Wiesser *et al.* desarrollaron el método de Vienna [WIE98] que utiliza la salida de modelos de corriente y voltaje para estimar el par electromagnético de un motor de inducción alimentado por convertidor [WIE98], [WIE99]. Este método también ha sido utilizado en la detección de asimetrías en el rotor [KRA02], [KRA05]. Las desventajas de este método son que necesita dos sensores, de corriente y voltaje; además, no puede dar una adecuada cuantificación del grado de falla debido a que se ve afectado doblemente por la velocidad de reacción [BELL01].

3.2.3 Corriente en el estator

3.2.3.1 Análisis en estacionario y transitorio

La corriente demandada por un motor de inducción ideal tiene una sola componente. En caso de cualquier asimetría mecánica o magnética, otros componentes frecuenciales aparecerán en el

espectro de la corriente estática de la máquina. El análisis espectral de la corriente del motor (MCSA) consiste en la detección de la corriente del motor y utilizar los resultados del análisis de su espectro para identificar una falla desarrollada o incipiente en el MI [SID05], [HAY89], [HAY90], [BET03], [DUQ05]. La corriente estática es detectada durante su funcionamiento normal o en el arranque.




Figura 3.2 Espectro de un motor con una barra rota donde se resalta la diferencia de amplitud entre la componente fundamental y la banda lateral superior.

Cuando una barra del rotor está rota, no fluye corriente a través de ella, y consecuentemente, no se genera flujo magnético alrededor de la barra. Este fenómeno genera una asimetría en el campo magnético del rotor producida por un campo rotativo de sentido inverso que gira a la velocidad de la frecuencia de deslizamiento con respecto al rotor. Por lo tanto, induce corrientes armónicas en el bobinado del estator, corrientes que se superponen a las corrientes estáticas. Estos armónicos superpuestos son usados como señales para la detección de barras rotas en motores de inducción en técnicas basadas en el MCSA [BAN99], [DUQ05]. El análisis del espectro de la corriente estática revela componentes de las bandas laterales, f_b , alrededor del armónico fundamental en caso de haber barras del rotor agrietadas o rotas. Generalmente el valor de f_b se calcula a la frecuencia $(1 \pm ks)f_s$, donde $k=1,3,5\dots$ y f_s es la frecuencia fundamental. La banda inferior $(1-2ks)f_s$ es especialmente consecuencia de las barras rotas, mientras que la banda superior $(1+2ks)f_s$ es considerada como consecuencia de la oscilación de la velocidad y el fenómeno de saturación [BEL01]. Sin embargo, hay otros componentes frecuenciales propuestos como signos de barras rotas en el espectro de la corriente estática, i.e. $f_b = [(k/p)(1-s) \pm s]f_s$ donde p es el número de pares

de polos y $k/p=1,3,5,\dots$ [GAY79], [KLI88]. Tal como se muestra en la Fig. 3.2, la diferencia de amplitud entre la fundamental y la banda inferior es usada para distinguir entre un motor sano y otro con una posible barra rota.

Tabla 3.1. Correlaciones propuestas para la estimación de la severidad de falla en el rotor [REZ11].

<u>Referencia</u>	<u>Componente de la corriente</u>	<u>Estimación del número de barras rotas</u>	<u>Definición</u>
[HAR82]	$(1 - 2s)fs$	$\frac{I_{(1-2s)fs}}{I} = \frac{\text{sen}\alpha}{2p(2\pi - \alpha)}$	$\alpha = \frac{2\pi pn}{N}$
[HIR94]	$(1 - 2s)fs$	$\frac{n}{N} = \frac{2I_{(1-2s)fs}}{I + 2pI_{(1-2s)fs}}$	
[THO01]	$(1 \pm 2s)fs$	$\frac{I_{(1-2s)fs}}{I} = \frac{n}{2N - np}$	
[FIL92]	$(1 \pm 2s)fs$	$\frac{I_{(1-2s)fs}}{I} = \frac{n}{N}$	
[BRU06]	$(1 - 2s^{(v)})\varpi^{(v)}$	$\frac{2\Gamma^{(v)}}{p} = \frac{n}{N}$	$\Gamma^{(v)}(s, \varpi) = \Gamma(s^{(v)}, \varpi^{(v)}) = \frac{I_{(1-2s^{(v)})\varpi^{(v)}}}{I_{(\varpi^{(v)})}}, v = 5,7,9,\dots$

Algunos investigadores han propuesto un criterio específico, en el espectro de corriente, para determinar la severidad de la falla [HAR82], [HIR94], [THO01], [FIL92], [BRU06]. La Tabla 3.1 [REZ11] muestra las correlaciones propuestas para estimar la severidad de falla en el rotor. Siau *et al.* [SIA04] investigaron la eficiencia de estas ecuaciones para determinar el número de barras rotas en MI. Ellos dedujeron que la amplitud de las bandas laterales depende de la carga y de la cantidad de barras rotas. En concordancia con ellos, Didier *et al.* [DID07] y Acosta *et al.* [ACO06] afirmaron que hay tres factores que influyen en la amplitud de las bandas laterales, *i* la inercia de la carga, el par de la carga del motor (la corriente en las barras del rotor) y la severidad de la falla del rotor. Bellini *et al.* [BEL08a] presentaron una extensa explicación de las correlaciones propuestas e indicaron los factores que afectan a la exactitud del número de BR determinado usando cada ecuación. También resaltaron que algunos fenómenos como la saturación, las corrientes entre barras y la asimetría magnética determinan la precisión del diagnóstico de barras rotas basado en MCSA. La saturación magnética induce un tercer armónico en la corriente estática, apareciendo un componente a la frecuencia $(1+2s)f_s$ en el espectro de la corriente estática [BEL08a]. La asimetría magnética también crea un componente espectral a la frecuencia $(1-2s)f_s$ en el espectro de la corriente estática [BEL01], [BEL02]. Consecuentemente, el diagnóstico de BR basado en MCSA es efectivo solamente si los fenómenos mencionados no están presentes. Las corrientes

entre barras disminuyen las asimetrías causadas por las fallas en las barras del rotor y por consecuencia, el diagnóstico basado en MCSA falla [MUL03]. Razik *et al.* [RAZ09] presentaron un novedoso método para detección de BR usando el espectro de la corriente cuando hay corrientes entre barras.

Un método de detección de BRs necesita una excelente precisión para la localización de las frecuencias características de fallo relacionadas a barras rotas, f_b , en el espectro, i.e., ambos, frecuencia fundamental y deslizamiento deben ser determinados con buena precisión [YE06]. Tradicionalmente, las técnicas basadas en MCSA analizan en estado estacionario los componentes espectrales de la corriente estatórica, sin embargo, la señal es esencialmente variable en el tiempo y es difícil obtener condiciones estacionarias durante el periodo de adquisición de datos. Además, hay aplicaciones donde la operación a velocidad constante no se consigue [DOU04]. Para lidiar con estos problemas, varias técnicas para determinar la velocidad del MI han sido desarrolladas [FER92], [JAN95], [HUR96], [HUR97], [BLA97]. Filipeti *et al.* [FIL98] demostraron que el componente de la banda lateral inferior depende fuertemente de la inercia motor-carga. Sin embargo, apuntaron que la suma de las dos bandas laterales relativas a la fallas puede ser usado como criterio cuantificador de la falla de BR sin depender de la inercia. Recientemente, Rodríguez *et al.* [ROD08] verificaron que la amplitud de la banda lateral superior apenas varía con la carga y este armónico se debe a la consecuente oscilación de la velocidad. Ayhan *et al.* [AYH06] propusieron una metodología de detección de BR bajo diferentes condiciones de carga utilizando técnicas de procesamiento de señales avanzadas. Salles *et al.* [SAL00] estudiaron una red neuronal para agrupar y clasificar anomalías de la carga como oscilaciones del par, repetitivas depresiones (*dip*) del par y anomalías del rotor tales como barras rotas.

El análisis del espectro de frecuencia de la corriente estatórica se ha realizado mayoritariamente con técnicas tradicionales de procesamiento de señales basadas en la transformada de Fourier, como la transformada discreta de Fourier o la transformada rápida de Fourier [SCH95], [TRZ00]. A pesar de su simplicidad, estas técnicas sufren de varios inconvenientes como fuga espectral, resolución frecuencial y ruido, lo que restringe su confiabilidad [KIA06]. La fuga espectral del armónico fundamental obscurece los componentes armónicos de interés [FIL95]. Este problema empeora cuando el MI opera con bajo deslizamiento porque en este caso la frecuencia f_b está muy cerca del armónico fundamental [TSO08], [DUQ06]. El filtrado de la señal ha sido propuesto para solucionar este inconveniente pero es difícil filtrar el armónico fundamental sin afectar a las bandas laterales [MEH11]. Por lo tanto, para poder separar diferentes líneas frecuenciales ligadas a

diferentes fenómenos es vital una alta resolución. Para aumentar la resolución frecuencial y disminuir la fuga espectral Kliman [KLI91] propuso la utilización de largos intervalos de adquisición de datos. No obstante, largos periodos de muestreo conlleva espectros de baja calidad debido a la variación de la señal con el tiempo a consecuencia de la variación de la carga, par o frecuencia de suministro durante el largo periodo de adquisición de datos [KLI91]. Además, periodos de muestreo más largos aumentan el costo computacional y esto no siempre es viable debido a limitaciones de memoria de los sistemas digitales. Otra limitación del tiempo de muestreo son las restricciones de los sistemas en tiempo real [BEL08b]. Otro inconveniente del análisis del espectro basado en la transformada de Fourier es la aparición de ruido que dificulta la detección de fallas incipientes.

Las técnicas de detección de fallas convencionales basadas en MCSA tienen más inconvenientes cuando se usan sistemas variadores de velocidad [YE06]. Como ejemplo de esto, la dispersión de frecuencia del convertidor aumenta la necesidad de un análisis de alta frecuencia, mientras que la detección de fallas requiere un análisis de alta resolución del espectro [BEL08b]. En consecuencia, una gran cantidad de trabajos se han desarrollado intentando obtener una metodología de detección de fallas en MI, de ser posible independiente de las condiciones de toma de muestra, utilizando técnicas avanzadas de procesamiento de datos, combinado con inteligencia artificial entre otros [DID07], [BEL02], [YE06], [TSO08], [BEL08b], [AYD11].

Thomson, Elder y sus colaboradores [THO83], [ELD89] sugirieron que la detección de fallas en motores de inducción podría ser más precisa si se mide y analiza la corriente durante la puesta en marcha del motor. Proponían que el análisis del espectro de la corriente de arranque de la máquina provee mejores oportunidades para la detección de fallas de MI. Las principales ventajas del análisis del espectro de la corriente transitoria son el elevado deslizamiento inicial y el gran ratio señal-ruido, pudiéndose separar fácilmente los componentes espectrales [BRI08b]. Durante la puesta en marcha, el componente $(1-2s)f_s$ varía de 0 a 50 Hz, por lo tanto puede ser identificado fácilmente en el rango 10-40 Hz, distante de la componente fundamental [TSO08]. Además, fue confirmado por [DOU04], [YAC98] que la detección de fallas utilizando la corriente transitoria es independiente de las condiciones de carga. Otra componente característica de BR fue propuesta por Faiz y Ebrahimi [FAI08] para diagnóstico de MI durante la puesta en marcha a la frecuencia $(4+3k)sf_s$.

El mayor obstáculo para la monitorización de la corriente transitoria de arranque es su periodo relativamente corto de establecimiento, por lo tanto se necesita un espectro de alta resolución para obtener un análisis y diagnóstico preciso. Yacamini *et al.* [YAC98] y Arui [ARU95] mejoraron el monitoreo de la corriente transitoria usando un enfoque de espectro con frecuencia variante en el tiempo. Sin embargo, la resolución frecuencial resultante no era suficientemente buena, y el espectro resultante difícil de analizar. Más atención se ha puesto en aplicar técnicas de procesamiento de señales modernas para mejorar la detección de BR en motores de inducción utilizando la corriente de arranque [DOU04], [BRI08b], [WAT98], [ANT06], [ANT07], [ANT09A]. La aplicación de modernas técnicas de tratamiento de señales combinada con clasificadores inteligentes ha mostrado progresos significativos en la detección de fallos basados en la monitorización de la corriente transitoria. No obstante, es necesario aclarar que relativamente poca atención ha sido enfocada a la detección de fallas usando la corriente de arranque comparada a la corriente de operación normal [REZ11]. Esto podría deberse a la dificultad de extraer los componentes de fallos de la señal de la corriente de arranque debido a que ésta es extremadamente inestable y de duración relativamente corta [ZHA03]. Hay que recordar que las frecuencias de las componentes de fallo asociadas a barras rotas dependen del deslizamiento, y por lo tanto, varían conforme el motor arranca [DOU04]. Además, no siempre es factible detener la operación del motor para poder realizar la medición. Por otro lado, es generalmente deseable que el motor sea constantemente monitorizado para detectar el inicio de la falla.

3.2.3.2 Vector de Park

La técnica de detección basada en el Vector de Park busca la identificación de un patrón específico de corriente obtenida de la transformación de las tres fases de la corriente estática a un sistema equivalente de 2 fases. Bajo condiciones ideales, la corriente trifásica equilibrada del motor conduce a un Vector de Park circular centrado en el origen de coordenadas. Bajo una falla, el Vector de Park se vuelve elíptico [REZ11]. La elipticidad del vector es proporcional a la severidad de la falla, y la orientación de su eje mayor depende de la fase de la falla. El espesor relativo del diseño fue utilizado para diagnosticar barras rotas en MI [AWA03].

Cruz y Cardozo [CRU00] introdujeron un nuevo enfoque basado en el análisis espectral del módulo del Vector de Park de la corriente estática, para detectar fallas del rotor en motores de inducción de tres fases. Indicaron que las componentes características de falla se encuentran a las frecuencias $2sf_s$ y $4sf_s$ en el espectro obtenido por el Vector de Park extendido y que son fácilmente separables

debido a que están distanciadas de la fundamental y que la amplitud de ésta es reducida por la transformación de Park. Sin embargo, Zhang *et al.* [ZHA07] declararon que las componentes características de fallas no son detectables usando el Vector de Park cuando el motor opera en vacío o con baja carga.

En otro estudio, Cruz y Cardozo [CRU01] usaron el Vector de Park para diferenciar los efectos de una falla en el rotor de una carga variable en el tiempo. Cuando la carga tiene una componente oscilante de baja frecuencia el Vector de Park es una elipse orientada a lo largo del primer cuadrante de los ejes coordinados. Sin embargo, en presencia de una falla en el rotor, la elipse se orienta a lo largo del segundo cuadrante del eje de coordenadas. Con este método, la suma de las amplitudes de las bandas laterales puede ser usada para eliminar el efecto de fluctuaciones de velocidad y de la inercia en el diagnóstico de fallos [CAR88], [CAR95]. Otros ejemplos de detección de barras rotas utilizando el Vector de Park puede encontrarse en [HAJ01], [LIU04].

Acosta *et al.* [ACO06] verificaron que el Vector de Park es apropiado para la monitorización de fallas en el bobinado del estator.

El enfoque del Vector de Park tiene algunas limitaciones tales como que ignora las no-idealidades de los motores de inducción y el inherente desequilibrio de la tensión del suministro eléctrico. Además, es difícil diferenciar entre diferentes fallas utilizando este método debido a que diversas fallas pueden causar efectos similares en el Vector de Park. Más aún, para una falla específica, la información contenida en una fase de la corriente es igual a la que aporta el Vector de Park. Obviamente, la adquisición de las tres fases requiere un mayor esfuerzo computacional y esta información puede ser utilizada para sistemas de diagnóstico más completos, dedicados a la detección de otras fallas [BEL01].

3.2.3.3 Instantes de cruce por cero (Paso por cero)

Cahs y Ckir [CAL07] presentaron un método de detección de BR basado en los instantes de cruce por cero de la corriente estatórica. En vez de muestrear la corriente del motor con un convertidor analógico-digital de alta resolución, se registran solamente los instantes de paso por cero de la onda. Las fluctuaciones en los intervalos del paso por cero de la onda de corriente de las tres fases son analizadas en el dominio de las frecuencias [CAL07]. El componente de frecuencia $2sf_s$ del espectro es considerado como un índice de falla del rotor. En el mismo trabajo mostraron que esta componente es independiente de desequilibrios en el suministro eléctrico. Sin embargo, también se

ha apuntado que actualmente no es posible proponer un umbral aceptable que garantice la sensibilidad de la detección [CAL08].

3.2.3.4 Envolvente (Envelope)

La magnitud instantánea de la corriente estatórica, llamada análisis de envolvente, es otro método para detección de fallas en MI. Las barras rotas producen una envolvente que se repite cíclicamente a un ritmo del doble del deslizamiento por la frecuencia fundamental ($2sf_s$) [ZHA07], [SIL08]. El análisis de envolvente puede ser usada para la representación y modulación de la señal tanto temporal como espectral [JAK03]. Típicamente hay tres métodos para el análisis de la envolvente: demodulación de la amplitud de la transformada Hilbert; filtro-demodulación; y demodulación pasa alto del valor absoluto [ZHA07]. La transformada de Hilbert es generalmente usada para extraer la envolvente de la señal de corriente para detección de barras rotas [ZHA07], [JAK03], [HED09]. Se utiliza la transformada de Hilbert debido a que aumenta la resolución tanto en frecuencia como en amplitud [JAK03].

Comparado con el método extendido del Vector de Park, esta técnica probó ser más sensible bajo condiciones de poca carga [ZHA07], [HED09]. Sin embargo, el tipo de procesamiento de señal aplicado es clave para este método. Así, Silva *et al.* [SIL08] no consiguieron una buena precisión al detectar barras rotas con cargas inferiores al 50 % del par nominal. Declararon que el método presentado no solo detecta si ocurre o no el fallo, barra rota, sino que también puede determinar el número de barras rotas, es decir, determina la severidad del fallo. Además, solo se necesita una fase de la corriente para la detección de fallas, lo que implica menores costos que el método de vectores espaciales que necesita de las tres fases [ZHA07], [HED09]. Supangat *et al.* [SUP05] propusieron una nueva técnica para la detección de BR basada en el análisis de la envolvente de la corriente de arranque. Ahamed *et al.* [AHA12] propusieron un método basado en el análisis de la envolvente de la corriente estatórica con wavelets discretas y transformada de Hilbert para la detección de barras rotas. Propusieron que el método puede ser extendido a otros tipos de fallo, aunque sin demostrarlo.

3.2.4 Monitorización del campo electromagnético:

Idealmente, el flujo en el entrehierro durante la operación normal de un MI sano varía sinusoidalmente en el tiempo y el espacio. Cualquier asimetría en el rotor o estator causa una desviación de dicho comportamiento sinusoidal [THO99a]. Una bobina enrollada alrededor del eje

puede medir la variación de la densidad de flujo en el entrehierro. Sin embargo, la colocación de dicha bobina directamente alrededor del eje es muy costosa y complicada, además de impracticable en muchos casos debido al tamaño del entrehierro en muchos motores. Elkasabgy *et al.* compararon el voltaje inducido en bobinas de prueba ubicadas sobre el eje mismo y exteriormente al motor [ELK92], concluyendo que la utilización de bobinas externas al motor permite detectar barras rotas. Otros investigadores como Henaó, Yazidi, Bacha corroboraron que detectores externos de flujo pueden detectar fallas en el rotor [HEN03], [YAZ05], [BAC07]. Este método ha mostrado ser efectivo en la detección de excentricidad en el entrehierro, tanto estática como dinámica [MAI92], [PEN94]. Sin embargo, no está extensamente implementado en la industria debido a algunos inconvenientes técnicos que presenta [BAC07], [THO97b], [THO98], [THO99b], [TOL96], [BIK06]. Por ejemplo, la posición de la bobina de prueba influencia el valor medido y en ocasiones no es posible colocar la bobina para asegurar una medición correcta. Además, el tamaño de la bobina está relacionado con el tamaño del motor. Por último, el análisis del flujo axial y en el entrehierro no puede ser cuantificado en función de la severidad de la falla [MEH11].

3.2.5 Voltaje inducido:

En 1992 Elkasabgy *et al.* [ELK92] introdujeron un método de monitorización para BR basado en la observación del voltaje inducido en el estator después de la desconexión del motor de inducción. Cuando el motor es desconectado de la red de suministro eléctrico, la corriente estática rápidamente decrece hasta cero, ya que la única fuente de voltaje en el devanado del estator es la corriente que circula por el rotor. Si alguna barra del rotor está rota, está influenciando el voltaje que se induce en el bobinado del estator. En un motor sano, la fuerza magnetomotriz producida por la corriente de las barras del rotor al desconectarse las fases del estator, es predominantemente sinusoidal. Por lo tanto, el voltaje inducido en el bobinado del estator debido a estas fuerzas magnetomotrices no debería tener ningún contenido armónico diferente al fundamental debido a la distribución de corrientes en el rotor. Sin embargo, en presencia de una barra rota la forma de la onda magnetomotriz se desviará de su natural forma sinusoidal y estas desviaciones pueden ser constatadas en el voltaje inducido en el estator. Se considera que esta técnica es suficientemente confiable para la detección de barras rotas, inclusive para máquinas sin carga debido a que pueden ser removidas las no-idealidades de la fuente como desequilibrios, presencia de armónicos etc. y no-linealidades de las características magnéticas de la máquina debido a la saturación [MIL99]. Sin embargo, la técnica tiene algunas limitaciones cuando se aplica en la práctica, i.e. requiere que las

pruebas se realicen con el motor sano para desarrollar una respuesta de línea base, y también es sensible a cambios en la carga, inercia del sistema, temperatura del rotor y la tensión de suministro [SUP07]. Además, se ha demostrado que el número de barras rotas no tiene mucho efecto en la magnitud de los componentes armónicos. Por otro lado, las corrientes entre barras, la dependencia de la amplitud espectral al momento de la desconexión y la corta duración de los datos, afectan adversamente la eficiencia de la técnica de detección [MIL99]. Sin embargo, se han realizado más estudios para mejorar la detección de BRs mediante técnicas avanzadas de procesamiento de señales [SUP07], [CUP04]

3.2.6 Velocidad angular instantánea

Otra posible forma de monitorización y diagnóstico de motores de inducción es la medición y análisis de la velocidad angular instantánea, VAI, debido a que puede proporcionar información acerca de la dinámica de la máquina. La velocidad angular instantánea se refiere a la velocidad angular que ocurre en una vuelta del eje [SAS06]. El monitoreo de la VAI es de interés para la detección de fallas en el rotor debido a que las pulsaciones del par ocasionadas por fallas en el rotor, alteran o modulan la velocidad del rotor [SAS06]. Gaydon [GAY79], Feldman y Seibold [FEL99] demostraron la capacidad de la monitorización de la VAI para detectar el tamaño y localización de los defectos del rotor. Esta técnica es menos conocida que otros métodos tradicionales, sin embargo, algún progreso en esta técnica ha sido presentada por Sasi *et al.* en años recientes [SAS06], [SAS01a], [SAS01b], [SAS03].

Entre los varios inconvenientes de esta técnica, el mayor es que los sistemas mecánicos rotan, en la práctica, con velocidad angular fluctuante, a pesar de la suposición teórica de que giran a velocidad constante. Sweeney y Randall [SWE95] demostraron que un sistema de transmisión basado en cojinetes puede tener fluctuaciones en su VAI inherentes debido a una combinación de efectos como errores geométricos, defectos en el rotor o desalineamientos [REZ11]. Además, la medición de la VAI es inevitablemente influenciada por ruido producido por variaciones en la carga o el suministro eléctrico y errores de medición debidos a ruido térmico de los circuitos de amplificación, filtro y digitalización. Este ruido deteriora la eficiencia de la técnica como se ha estudiado por Gu *et al.* en [GU06]. Sasi *et al.* explican detalladamente las ventajas y desventajas de este método [SAS04].

3.2.7 Potencia instantánea

La potencia instantánea, PI, $p(t)$, se define como $p(t)=v_{ll}(t)I_l(t)$, siendo $v_{ll}(t)$ el voltaje entre dos de los tres terminales del estator e $I_l(t)$ la corriente entrando a uno de esos terminales [LEG96]. Los voltajes y corrientes estáticas son medidas y luego la potencia instantánea de una fase es calculada [REZ11].

Hay diferentes tipos de potencia instantánea, PI, monitorizadas para la detección de fallas en MI, nombradas como PI parcial referida al componente constante de la potencia, PI parcial referida a la fundamental y PI total. El espectro de la PI parcial contiene 4 componentes, una constante (dc component), una componente a la frecuencia $2f_s$, componentes a las frecuencias $(2 \pm 2ks)f_s$, donde k toma valores enteros, f_s es la frecuencia fundamental y s el deslizamiento, además de componentes adicionales a frecuencias de $2ksf_s$ [LIU 04]. En este espectro, la presencia de barras rotas se nota en las bandas laterales alrededor del doble de la frecuencia fundamental $(2\pm 2s)f_s$ [TRZ00] y en los componentes característicos de falla $2sf_s$ a bajas frecuencias. Sin embargo, en el espectro de PI total, la falla sólo se nota en la frecuencia característica $2sf_s$ [CRU99].

Trzynadlowski y Ritchie [TRZ00] y Eltabach *et al.* [ELT07], [ELT09], [ELT04] compararon el análisis de onda de estos 3 tipos de PI con otras técnicas de diagnóstico para la determinación de BR bajo diferentes niveles de carga. Estos trabajos apuntaron que la PI referida a la fundamental tiene la mayor sensibilidad a las fallas del rotor [ELT04]. Una aplicación de diagnóstico basado en medición de la PI para detección de BR fue investigada y desarrollada en [KIA06], [LIU 04], [DID03A], [DID03b]. Por ejemplo, Didier *et al.* [DID06] demostraron que una barra medio-rotas con carga de 25% puede ser detectada efectivamente con esta técnica. Aún más, la monitorización de la PI fue más efectivo para la separación de fallas mixtas (BR, excentricidad, fallas en cojinetes) y en la cuantificación del grado de falla en comparación a la monitorización de la corriente y el voltaje [LIU 04], [LU08].

Drif y Cardoso [DRI07], [DRI09] introdujeron una nueva propuesta basada en el análisis espectral de la potencia reactiva para el diagnóstico de BR en motores de inducción. Su estudio se basó en el análisis de la componente característica de falla $2sf_s$, mostrándose que esta componente es afectada visiblemente aún con una sola barra rota sin carga en el motor [DRI09]. De Angelo *et al.* [DEA10] analizaron la efectividad del estudio de la PI activa y reactiva para la discriminación de BR con carga oscilante. Analizando las componentes de baja frecuencia demostraron que las barras rotas

afectan a la potencia reactiva, mientras que la oscilación de la carga afecta a la potencia activa instantánea.

A pesar de todas las ventajas del uso de la PI, Ballini *et al.* sostienen que este método pierde información y por lo tanto no permite una adecuada cuantificación de la avería, porque se ve afectado doblemente por la velocidad de reacción [BEL01]. Otro inconveniente de este método es la necesidad de dos sensores para medir 2 señales eléctricas [LIU04] o 6 señales [KIA06], [CRU99] dependiendo del estudio.

3.2.8 Análisis circuital del motor

Penrose y Jette [PEN01a] propusieron un análisis circuital del motor basado en la medición de las propiedades electromagnéticas del motor de inducción para determinar la presencia de cualquier variación dentro del mismo. Esta técnica incluye ensayos sencillos como la medición de la resistencia e inductancia del motor, y ensayos de propiedades más complejas del MI que se llevan a cabo con el motor desenergizado. Para tener una representación adecuada de la condición del motor se requiere la medición de resistencia, impedancia, ángulo de fase e inductancia, según Penrose y Jette [PEN01a]. Sostienen que debido a que en el análisis circuital del motor se aplica una pequeña cantidad de energía con respuestas amplificadas, estas respuestas ayudan en la evaluación de la condición tanto del rotor como del estator, a través de lecturas comparativas [PEN01a], [PEN01b], [PEN02], [PEN03], [PEN04a]. Penrose y su grupo son los únicos que han utilizado este método para la detección de fallas en motores de inducción [MEH11].

3.2.9 Ensayos de sobretensión (Surge test)

Surge test, que usa adaptación de impedancia (*impedance matching*) al aplicar una sobretensión (*surge*), es un método bien conocido para el diagnóstico de fallas en el bobinado [SID05], [THO95], [KOH99]. Sin embargo, Huang *et al.* [HUA07] introdujeron un nuevo método para la detección de excentricidad del rotor usando este procedimiento. Según ellos, el grado de excentricidad del entrehierro afectaría a la frecuencia de resonancia de una sobretensión sinusoidal. En otras palabras, la excentricidad en el rotor causa una asimetría en el entrehierro, lo que condiciona la forma de la onda de sobretensión según la posición del rotor, es decir, la forma de la onda de sobretensión fluctúa a medida que gira el rotor debido a la excentricidad del mismo. Por lo tanto, el cambio de la forma de la onda de sobretensión por revolución puede ser usada para indicar el problema en el entrehierro. La amplitud de la componente fundamental en el dominio de la

frecuencia de un MI con fallo fue comparado con datos históricos, obtenidos de un motor sano, para indicar la severidad del fallo. Finalmente, ellos afirman que la prueba de sobretensión (*surge test*) es un método efectivo, económico y confiable que es particularmente útil en el mantenimiento predictivo de rutina [HUA07].

3.2.10 Vibraciones

El análisis de vibraciones es generalmente usado para el diagnóstico de fallas mecánicas como fallas en los cojinetes, engranaje de acoplamiento, desalineamiento del rotor y desequilibrio [KRA03]. Las vibraciones de la carcasa también pueden deberse a cortocircuitos en el bobinado del estator, desequilibrio en el suministro [TAV86] o barras rotas [MEH07]. Las vibraciones son medidas en dirección radial o axial, y los transductores pueden ser colocados en los cojinetes si se pretende detectar fallas mecánicas [WAN00]. Sin embargo, al colocar los transductores en la carcasa del estator también se pueden detectar fallas en el rotor [TRU02].

McCully y Landy fueron los primeros en demostrar que las barras rotas perturban el campo electromagnético y por lo tanto intensifican las pulsaciones del par y las vibraciones de la caja [MCC97]. Señalaron, sin embargo, que el análisis de vibraciones no provee suficientes datos si no hay corrientes entre las barras. Los mismos autores cuantificaron las frecuencias de las vibraciones radiales causadas por las corrientes entre barras originadas en una falla del rotor y propusieron un nuevo método de detección de barras rotas [MUL03]. Li and Mechefske [LI06] compararon el análisis de vibraciones con el MCSA y análisis de ruidos en presencia de BR y fallas en los cojinetes bajo diferentes velocidades y condiciones de carga. Concluyeron que el análisis de corriente, MCSA, es el método más sensible para la detección de barras rotas, mientras que el análisis de vibraciones es más efectivo para detectar fallas en los cojinetes. Kral *et al.* también concluyeron que el análisis de vibraciones es eficaz para la detección de fallas en cojinetes y otras averías estrictamente mecánicas [KRA03]. Timusk *et al.* [TIM08] desarrollan una estrategia para la monitorización online de vibraciones y detección de fallas en una clase particular de máquinas. Shen *et al.* [SHE13] emplean señales de vibraciones para detectar fallos en los cojinetes y caja de engranajes de un motor de inducción. Emplean parámetros estadísticos y *wavelet packets* para extraer las características indicativas de fallo de la señal de vibraciones y un clasificador regresivo genérico con vectores de soporte para el diagnóstico.

Li and Mechefske [LI06] también señalaron que, contrariamente a lo que ocurre con la corriente estatórica, la amplitud de las bandas laterales del espectro de vibraciones depende más de la

velocidad del motor que de la carga externa. Aunque el análisis de vibraciones demostró ser sensible a las fallas tanto del rotor como del estator, tiene algunas desventajas. Su principal desventaja es la necesidad de contar con información detallada del diseño del motor, como el conocimiento de las funciones de respuesta en frecuencia. Esta información es necesaria porque las respuestas mecánicas y eléctricas variarán de acuerdo a la posición del acelerómetro, lo que dificulta la cuantificación de la falla [LIA03]. También en [KRA03] se señala que la cuantificación de fallas es más intrincada utilizando el análisis de vibraciones [REZ11].

3.2.11 Voltaje

Razik y Didier [RAZ04] propusieron un método basado en el análisis espectral del voltaje entre la línea de alimentación y el neutro del estator, para la detección de barras rotas. Las barras rotas causan asimetrías en la inductancia mutua de la máquina, esto provoca un aumento de los componentes armónicos del voltaje línea-neutro [OUM06]. Razik y Didier [RAZ04] investigaron la monitorización del voltaje línea-neutro para la detección de BR en motores de inducción bajo carga severa. Simulaciones y experimentos probaron la efectividad de este método inclusive para la detección de barras parcialmente rotas. Recientemente se han reportado más investigaciones sobre esta técnica de detección de fallas [OUM06], [BAB06], [OUM07], [KHE09], donde se declara que el análisis del voltaje línea-neutro no solo tiene las ventajas y simplicidad del MCSA, sino que además posee una mayor sensibilidad a las fallas del motor. Por ejemplo, considerando la detección de BRs, más armónicos con mayor amplitud pueden ser considerados como característicos de la falla [RAZ04]. Sin embargo, esta técnica está lejos de estar desarrollada y necesita aún de mucho esfuerzo para mejorar su desempeño en el diagnóstico global de fallas en motores de inducción [REZ11].

3.2.12 Temperatura

El sensor de temperatura se puede montar en el bobinado o incrustado en el aislamiento, que está aislado eléctricamente de su instrumentación [TAV86]. La estimación de la temperatura puede estar basada en el modelo térmico y en el modelo de la resistencia del estator, si está asegurada la ventilación sin obstrucciones, y si la temperatura ambiente es considerada como factor para la elevación de la temperatura del motor o refrigeración del mismo [SID05], [SAI02]. Castellon *et al.* utilizaron el método de paso térmico (TSM) que considera el fenómeno de la carga espacial como una consecuencia del envejecimiento del aislamiento del estator [CAS97]. También emplearon la

técnica de medición de corrientes de descarga térmicamente estimuladas (TSDC) para obtener los niveles de energía de las cargas. Mediante la asociación de los métodos TSM y TSDC, se puede realizar un estudio completo de la aparición y del desarrollo de las cargas espaciales y se puede predecir el tiempo de vida de aislamiento del estator [CAS97]. Un aparato de diagnóstico no destructivo ha sido desarrollado utilizando un sensor de plástico de fibra óptica (POF) para evaluar el envejecimiento de aislante de resinas para motores de inducción de baja tensión. Este aparato mide el cambio de relación de absorbancia reflectante en dos longitudes de onda diferentes y cercanas al IR [TAK98].

Picazo *et al.* [PIC12] propusieron una metodología para calcular el balance de energía y la curvas de calentamiento de un motor de inducción usando como datos las características geométricas del motor y la información proporcionada por imágenes de termografía infrarroja. Desarrollaron un modelo para calcular las pérdidas caloríficas a través de la carcasa del motor y tomando imágenes termográficas a intervalos de un segundo demostraron experimentalmente que se puede detectar una falla por barra rota analizando la evolución real del calentamiento de la carcasa del motor y comparándolo con el pronosticado por el modelo desarrollado. También proponen que diferentes motores y condiciones de operación pueden ser estudiados cambiando parámetros térmicos y geométricos del modelo matemático.

3.2.13 Análisis de gases.

La degradación del aislamiento eléctrico dentro del motor produce monóxido de carbono, gas que pasa al circuito de refrigeración del aire y puede ser detectado por medio de la técnica de absorción infrarroja, IR [SID05], [TAV86]. La modulación de alta frecuencia de ancho de pulso (PWM) genera excesivos gradientes de tensión que propician el deterioro de la aislación del motor. La producción de gas es el resultado de los campos electrostáticos que rodean los conductores de polarización contraria. El campo eléctrico generado es suficiente producir una ionización del aire circundante, generando ozono que se combina con el nitrógeno del aire para producir óxidos nitrosos. Estos óxidos atacan corrosivamente el aislamiento causando eventualmente la fractura. Se pueden emplear técnicas de extracción de ozono para su detección [RID99] y [ALL01]

3.2.14 Monitorización mixta

Varios estudios han presentado procedimientos de detección de fallas utilizando dos o más técnicas de monitoreo. Rangel-Magdaleno et al [RAN09] presentaron una novedosa metodología para la

detección de barras semi-rotas, la cual combina el análisis de corriente y vibraciones. El grupo de Yang *et al.* en diferentes trabajos propuso un avanzado esquema para la diagnóstico de fallas en MI basado en el análisis de vibraciones y corriente [YAN06], [WID07a], [WID07b], [NIU07], [HAN07], [TRA09]. En estos trabajos un complejo algoritmo basado en procesamiento de señales y extracción de características fue empleado para clasificar, distinguir y detectar una o más fallas en motores de inducción [REZ11].

3.3 Procesamiento de señales

Es muy difícil o casi imposible, obtener información a simple vista de una señal sin procesar. Además, la señal obtenida directamente de un instrumento midiendo un proceso físico siempre contiene alguna cantidad de ruido [REZ11]. El procesamiento de señales es un conjunto de técnicas que mediante diversos algoritmos computacionales analizan y transforman la señal original para obtener una representación significativa de la información contenida en la señal, al mismo tiempo que intenta suprimir o disminuir los efectos del ruido. De acuerdo a esto, una señal adquirida mediante una técnica de monitorización necesita ser analizada mediante un método de procesamiento de señales para obtener las características relacionadas con cada tipo de fallo para poder tomar una decisión. Las técnicas de procesamiento de señales se pueden separar en tres categorías, en el dominio del tiempo, en el dominio de la frecuencia y en el dominio tiempo-frecuencia. La elección del tipo de procesamiento depende de la naturaleza de la señal y de la información que se quiere obtener de ella [REZ11].

Los gráficos en el dominio del tiempo muestran cómo una señal cambia a lo largo del tiempo y el análisis de las funciones matemáticas o señales físicas se hace con respecto al tiempo. Funciones estadísticas comunes pueden ser usadas para describir la función de densidad de probabilidad de una señal variable en el tiempo. En el análisis en el dominio del tiempo, las características relativas a las fallas de la señal pueden ser extraídas calculando varias medidas estadísticas como el promedio, desviación estándar, Skewness, Curtosis, Factor de Cresta, Factor de Forma, error de entropía, estimación de entropía, límites superior e inferior del histograma, envolvente y la media cuadrática.

La señal sin procesar es transformada al dominio de la frecuencia usando diferentes técnicas de estimación espectral incluyendo métodos de estimación espectral paramétricos, no-paramétricos y de alta resolución [BEL08a], [AYH08]. Los métodos no-paramétricos se basan en la transformada

convencional de Fourier y los valores resultantes son generalmente presentados como amplitudes, potencias, intensidades o fases. El espectro incluye componentes relacionados a las fallas en observación. También hay algunas medidas estadísticas que pueden ser extraídas del dominio de frecuencia como el centro de frecuencia, la raíz media cuadrática de la frecuencia y la raíz de la varianza. El análisis de la densidad de potencia espectral PSD, es otra técnica ampliamente utilizada para la detección de fallas en MI. Además del análisis de la transformada de Fourier hay otros métodos de estimación para PSD, como el periodograma y el análisis de Welch. El análisis de la densidad espectral permite ver solamente diferentes frecuencias y sus amplitudes en una señal. El espectro de orden superior, definido en términos de estadísticas de orden superior, permite analizar el acoplamiento no-lineal entre frecuencias, ya que implican a las amplitudes y a las fases de la señal [COL98]. Por ejemplo, el bispectrum llamado espectro de tercer orden es definido en términos de la transformada de Fourier de dos dimensiones [BEN03]. Hay otro método de análisis llamado cepstrum, que es la transformada inversa de Fourier del espectro logarítmico. Entre los métodos paramétricos, la autoregresión AR es usada para establecer un modelo, como el Yule-Walker, Burg o covarianza, complementada con series temporales de la señal. Los parámetros del modelo son luego usados para computar el espectro de frecuencias. Un análisis de la señal más práctico es el método Prony que puede ser considerado como un método paramétrico de alta resolución. Este método extrae importante información de la señal y crea una serie de amortiguados (*damped*) exponenciales complejos o sinusoides. El método Prony permite la estimación de la frecuencia, amplitud, fase y componentes amortiguados (*damping*) de la señal [MAR89]. Métodos de alta resolución espectrales, como la clasificación de múltiples señales (MUSIC), ROOT-MUSIC y ZOOM-MUSIC, computan la matriz de autocorrelación de la señal y sus autovalores pueden ser separados en los espacios de la señal y del ruido. Otro tipo de técnica de alta resolución recientemente aplicada a la detección de fallas en motores de inducción es el algoritmo rápido de búsqueda ortogonal [KIN10A], [KIN10b]. También hay otros tipos de algoritmos estimadores de frecuencia basados en la FFT con mejoras de resolución como el zoom-FFT (ZFFT) y la chirp transformada Z [HED07a]. La transformada de Hilbert también ha sido utilizada para el diagnóstico y detección de fallas. Aydın *et al.* [AYD11] presentaron una pequeña revisión de la utilización de la transformada Hilbert en la detección de barras rotas en MI. En [PUC09] investigadores del departamento de Ingeniería Eléctrica de la Universidad Politécnica de Valencia proponen una técnica avanzada de procesamiento de la señal basada en la transformada de Hilbert para diagnosticar barras rotas con ensayos obtenidos a muy bajos deslizamientos.

Para superar el problema de las señales no-estacionarias, se ha propuesto el análisis de tiempo-frecuencia, que consiste en una representación en 3-d del tiempo, frecuencia y amplitud de la señal. Las representaciones tiempo-frecuencia más populares son la transformada de Fourier de tiempo reducido (STFT), la distribución Wigner-Ville y la transformada wavelet. La STFT divide toda la señal de la onda en estrechas ventanas de tiempo y luego aplica la transformada de Fourier a cada segmento. En [PIN09] Pineda *et al.* proponen una técnica, basada en la transformada de Hilbert, para la extracción de la frecuencia instantánea de la banda lateral izquierda durante el arranque del motor. También demuestran que la evolución de dicha frecuencia instantánea puede servir como un indicador universal de fallo por barra rota. Una limitación de esta técnica es que considera solamente el arranque con alimentación de red, por lo que es una línea de investigación abierta la manera de extender esta metodología al arranque con alimentación de variador. En [PIN10] el mismo grupo propone la utilización de la transformada de Fourier Fraccional con una transformada wavelet discreta como filtro previo de la corriente estatística durante el arranque. Muestran la utilidad de la técnica para la detección de barras rotas, aunque señalan que puede ser empleada para la detección de otros tipos de fallos como la excentricidad o el fallo en los cojinetes. En el mismo artículo indican que una limitación del método es la necesidad de arranques de más de medio segundo.

Otra representación espectral variante en el tiempo es el espectrograma, que puede ser estimado computando el cuadrado de la magnitud de la STFT de la señal original. La distribución Wigner-Ville es una transformación bilinear básica, que, al contrario de la STFT, no divide en segmentos la señal original. Se basa en la frecuencia instantánea, que es la derivada de la fase de la señal. La distribución Wigner-Ville es generalmente suavizada con funciones de filtro, esta distribución es llamada Pseudo-Wigner-Ville suavizada [LI06]. En [ANT09b] Antonino *et al.* utilizan la distribución Wigner-Ville para detectar fallo por excentricidad empleando la corriente de arranque. Otra transformada utilizada en el análisis tiempo-frecuencia es la transformada wavelet que es una representación de la señal en coordenadas tiempo-escala [JAR06], [ANT06], [ANT09a], [RIE09]. El análisis wavelet de una onda expresa la señal en una serie de funciones oscilatorias con diferentes frecuencias a diferentes tiempos. Esta transformada divide la señal en el espacio tiempo-escala y el tamaño de la ventana tiempo frecuencia (escala) no es rígido [DAU90]. Hay diferentes tipos de transformada wavelet ampliamente utilizadas en el monitorizado de motores de inducción. Más información incluyendo teoría y propiedades de las técnicas modernas de procesamiento de señales puede ser hallada en [FIL95], [BUR96], [JAR06], [SEJ09], [PEN04b], [HED07b].

3.4 Técnicas de clasificación

Los métodos de monitorización pueden ser clasificados en tres grandes grupos:

Monitorización de estado basada en modelos [AHM07]: En el enfoque basado en modelos, el efecto de ciertos fallos en las características indicativas de fallo se puede predecir mediante el uso de diferentes enfoques de modelado matemático de los fenómenos físicos que se desarrollan en la máquina. Por ejemplo, muchos autores, como en [AHM05], [FIS01] emplearon el método de Elementos finitos para la detección de barras rotas utilizando la corriente estatórica como señal a medir. En la investigación realizada en [THO 98], [TAL02] se describe una técnica de Modelo-Transitorio usando la señal de un corriente estatórica de una sola fase para detectar fallos de rotor y estator en motores de inducción. Otra técnica basada en un modelo es el Monitorizado Térmico, en el que la identificación de la resistencia del rotor se utiliza para detectar los fallos de rotor [BEG99].

En [BAN99], [POV02], un modelo de elementos finitos con pasos de tiempo acoplados y espacios de estado demostró ser útil para predecir los componentes característicos de fallo por barras y anillos conectores. En [COM01] un modelo Park¹ es utilizado para describir las variables eléctricas y se emplea la transformada wavelet para filtrar posibles variaciones en la velocidad. En este trabajo se consideran fallos en el bobinado del estator y barras rotas.

Lees *et al.* [LEE09] presentan una revisión de los métodos de detección de fallos en máquinas rotativas basados en modelos matemáticos de los fenómenos físicos que se desarrollan en los mismos.

Pennacchi *et al.* [PEN06a], [PEN06b] proponen un modelo modal² para considerar la influencia de la estructura de soporte en las técnicas de identificación de fallos basados en modelos de grandes maquinarias rotativas.

El uso de los métodos basados en modelos mencionados anteriormente proporciona una información completa de los sistemas dinámicos que intervienen en la detección de fallos. Sin

¹ Transformada propuesta por R. H. Park en la que las ecuaciones de que modelan al motor se asocian a un sistema marco de referencia que giran sincrónicamente con los campos magnéticos de la máquina.

² El análisis modal es el proceso de determinación de las características dinámicas inherentes de un sistema cualquiera en forma de frecuencia naturales, factores de amortiguamiento y modos propios de vibración, y su utilización para formular un modelo matemático que explique su comportamiento dinámico. Al modelo matemático formulado se le llama modelo modal del sistema y a la información de las características se le conoce como información modal [HER09].

embargo, en estos métodos la fiabilidad y exactitud de los resultados se basan en el uso de la información detallada del diseño electromagnético de la máquina, que normalmente no está disponible. Además, también es difícil usar los resultados obtenidos mediante el uso de métodos basados en el modelo de un motor para ajustar el umbral de fallo para otros motores [AHM07].

Los modelos basados en el conocimiento [MAR12]: estos métodos dependen del conocimiento humano del proceso y sus fallos. Los modelos basados en el conocimiento (tales como sistemas expertos o árboles de decisión) implementan esquemas basados en el conocimiento humano del proceso de diagnóstico de fallos. En el diagnóstico de fallos, el experto humano puede ser una persona que opera la máquina y que tiene experiencia en las distintas clases de averías que pueden afectarla. La base de conocimientos se puede construir mediante la realización de entrevistas con un operador humano sobre la incidencia de fallos en la máquina a ser diagnosticada. Los sistemas expertos son normalmente apropiados para este tipo de problemas, donde el experto humano lingüísticamente puede explicar la solución. Característicamente, el conocimiento humano es impreciso, y con frecuencia los sistemas expertos tradicionales han tenido problemas al lidiar con este tipo de información. Por ejemplo, el límite preciso en el que la temperatura es demasiado alta en una sauna es vago en las mentes humanas. De hecho, generalmente es muy difícil obtener datos suficientemente representativos del comportamiento sumamente complejo y no lineal del sistema defectuoso para hacer modelos cuantitativos. Los modelos basados en el conocimiento pueden ser aplicados en conjunto con diagnósticos simples basados en la señal, si el conocimiento experto para el proceso se encuentra disponible. Sin embargo, con frecuencia es difícil incluso para un experto humano diferenciar el funcionamiento defectuoso del correcto. Además, múltiples fuentes de información pueden ser necesarias para la toma de decisiones fiables. Por lo tanto, los modelos basados en datos generalmente son más flexibles para el monitorizado automático de la condición.

Un ejemplo de este método de diagnóstico se presenta en [TAN08], donde implementaron un sistema experto con redes neuronales para la detección de fallos en dragas. Utilizaron como datos de entrada una base de datos de procesos con información de los parámetros de las máquinas, temperatura, velocidad, potencia, posición, entre otros donde las reglas obtenidas de entrevistas con los expertos se emplean en paralelo con la clasificación hecha por las redes neuronales. Petković *et al.* [PET12] implementaron un sistema de agrupamiento adaptativo que utiliza un sistema experto como punto de partida para diagnosticar fallos en un sistema neumático. Silva *et al.* [SIL12] presentaron un sistema experto para el modelado, detección y mitigación de fallos y lo probaron en

un sistema de actuadores electromecánicos. Compararon su sistema con los obtenidos por una red neuronal mostrando resultados similares.

Los modelos basados en datos [MAR12]: estos métodos pueden ser implementados aun cuando el modelado físico del proceso es desconocido en una forma analítica o es muy complejo y el conocimiento de experto ante fallos está ausente. Los modelos basados en datos se pueden producir de varias maneras. Modelos basados en redes neuronales como el perceptrón multicapa (MLP) y la Función de Base Radial (RBF) se han aplicado extensamente para monitorizado de cojinetes. Samanta y Al-Bushi [SAM03a] aplicaron redes neuronales con características del dominio de tiempo para la detección de defectos de laminación en elementos de cojinete. Emplearon señales de vibraciones. Yang *et al.* [YAN04] implementaron la técnica ART-Kohonen (que combina la teoría de resonancia adaptativa ART y la estrategia de aprendizaje de las redes neuronales de Kohonen) para el diagnóstico de fallas de las máquinas rotativas, empleando también señales de vibraciones como entrada. Clasificadores basados en Kernel (núcleo) tales como las máquinas de vectores de soporte (SVM) se han aplicado al diagnóstico de fallos. En este sentido, Jack y Nandi [LAC02] compararon las máquinas de vectores soporte y redes neuronales para la detección de errores en máquinas rotativas empleando señales de vibraciones, y empleando algoritmos genéticos para reducir el número de variables inicialmente propuesto. Ambos métodos mostraron eficiencias similares en la clasificación pero las redes necesitaron menor tiempo de entrenamiento y demandaron menos recursos computacionales. Samanta *et al.* [SAM03b] implementaron las Redes Neuronales Artificiales (ANN) y máquinas de vectores de soporte (SVM) para la detección de fallos en cojinetes. Utilizaron características estadísticas del dominio del tiempo de la señal de vibración con un algoritmo genético para optimizar los parámetros de ambos clasificadores y reducir al mismo tiempo el número de características. Yang *et al.* [YAN05] aplicaron SVM multiclase para el diagnóstico de fallos en máquinas rotativas con wavelets para la extracción de características de la señal de vibración. Rojas y Nandi [ROJ06] aplicaron la SVM para la detección y clasificación de fallos en los elementos rodantes de cojinetes. Hu *et al.* [HU07] aplica una transformada wavelet packet y un ensamble de SVM para el diagnóstico de fallos de las máquinas rotativas.

Ertunc *et al.* [ERT01] aplicaron el modelo oculto de Markov (HMM) en estudios de desgaste de la broca en un proceso de perforación. Purushotham *et al.* [PUR05], Miao y Makis [MIA06] y Nelwamondo *et al.* [NEL06] también aplicaron el modelo oculto de Markov para diagnosticar fallos.

3.4.1 Detección de barras rotas con redes neuronales.

En los últimos años las redes neuronales han sido aplicadas exitosamente en varias ocasiones como técnica de clasificación o toma de decisiones en metodologías de diagnóstico de barras rotas en motores de inducción [SID05], [DON09], [KAM10], [VAN09].

Kaminski *et al.* [KAM10] implementaron una red neuronal de regresión general considerando la corriente estatórica como dato de entrada. Utilizaron como datos de entrada a la red neuronal la frecuencia de suministro eléctrico, las amplitudes de las bandas laterales a las frecuencias características de falla por barras rotas, f_b , y componentes de falla extraídos del módulo del vector espacial de la corriente estatórica. Esta última característica fue propuesta por estar los componentes de falla del módulo del vector espacial más separados del armónico principal que las bandas características de falla en el espectro de la corriente obtenido por la transformada de Fourier. Se hicieron 900 mediciones en motores con diferentes grados de falla en el rotor, de 0 a 9 barras rotas. Se dividieron en 3 grupos de 300 utilizando el método de validación cruzada para las pruebas de la red neuronal. El desempeño promedio, medido como el porcentaje de ensayos correctamente clasificados sobre el total, de estos dos vectores fue de 88 % aproximadamente.

Van Tung et al [VAN09] emplearon redes neurodifusas para clasificar varios tipos de fallos: desalineamiento angular, deflexión del rotor, barras rotas del rotor, fallas en los cojinetes, desequilibrio mecánico, desalineamiento paralelo, desequilibrio de fases (agregando resistencia). Compararon dos redes distintas, una utilizando datos de vibraciones y otra red utilizó mediciones de la corriente estatórica. En este estudio se utilizó un árbol de decisión y regresión para seleccionar las características más relevantes a ser empleadas como entradas a la red neuronal, tanto de las mediciones de vibraciones como de las medidas de la corriente. La red neurodifusa trabaja con una versión fuzzy o difusa de las reglas obtenidas en el árbol de decisión. Para presentar sus resultados mostraron una matriz de confusión. La red que utilizó datos de vibraciones obtuvo un porcentaje de clasificación correcta del 91 % aproximadamente mientras que la red que trabajo con mediciones de la corriente estatórica logró una clasificación correcta más baja, de poco más del 76 %. Es de resaltar que éste es uno de los pocos trabajos que no utiliza datos del espectro de frecuencia de la corriente, está podría ser la razón de la gran diferencia en el porcentaje de clasificación correcta.

Ghate y Dudul [GHA10] compararon una red perceptron multicapa y un mapa auto-organizado de tipo Kohonen considerando tres tipos de fallas: cortocircuito en el bobinado del estator,

excentricidad dinámica en el rotor y ambos a la vez. Inicialmente consideran 13 valores estadísticos de la corriente estática y optimizan ambas redes neuronales sugiriendo los parámetros para ambas redes. Luego se realizó un estudio estadístico de análisis de componentes principales para reducir la cantidad de parámetros estadísticos usados como datos de entrada a las redes. Ambas redes disminuyeron su complejidad con la disminución de datos de entrada manteniendo el nivel de clasificación correcta. Finalmente probaron los algoritmos con datos de entradas con ruido gaussiano y uniforme con media cero y varianza variable del 1 % al 20%. Los resultados son satisfactorios hasta ruido con varianza del 15 %.

Dong *et al.* [DON09] proponen una red neuronal difusa donde las funciones de pertenencia son construidas en base a datos premedidos. Utilizan mediciones del voltaje y la corriente donde las mediciones de entrada son preprocesadas para obtener los valores absolutos de las diferencias de fase, APVD (*absolute phase value difference*). Los APVD se calculan promediando la diferencia dos a dos del valor en las fases, es decir, se promedian las diferencias entre los valores absolutos de cada fase. Consideran dos tipos de fallo, rotura de barra y cortocircuito en el bobinado del estator. La salida distingue entre 4 posibilidades, sano, falla leve (1 barra rota o cortocircuito de una fase), media (2 barras rotas o cortocircuito de 2 fases) y peor posible (3 barra rota o cortocircuito de 3 fases).

Qing y Dong [QIN07] propusieron una red perceptrón multicapa con el deslizamiento, deslizamiento nominal, la amplitud de la corriente a la primera frecuencia característica de falla a la izquierda del armónico principal, el número de barras, la corriente y la potencia como datos de entrada. Consideran el motor sin averías, con una, dos o tres barras rotas. En el artículo solamente consideran 11 mediciones para entrenar y validar la red. Mati *et al.* [MAT10], implementaron una red perceptrón de capa única. Sólo consideran dos entradas, las amplitudes de corriente en las primeras frecuencias de fallo características, izquierda y derecha. Como salida obtienen valores entre -1, motor dañado y 1 correspondiente al motor sano. Realizaron únicamente 8 pruebas y proponen el método para la detección de fallas online por su simplicidad pero no lo implementan. Estos dos artículos utilizaron muchos menos ensayos que en los demás artículos del estado del arte para entrenar y validar las redes.

Germen *et al.* [GER07] propusieron un mapa auto-organizado o de Kohonen de 10 por 5 neuronas conectadas en estructura hexagonal. Utilizan como entrada un vector compuesto por los polos del plano Z del espectro de la línea de corriente en el rango de frecuencias de 40 a 60 HZ. Considera un

vector de 10 entradas. Realizaron 80 experimentos, 20 con el motor sin fallas, 20 con 3 barras rotas, 20 con 5 barras rotas y las últimas 20 con el rotor desalineado. Como metodología de prueba utilizaron “*One leave out*”, así utilizaron 79 ensayos para entrenar la red y el experimento restante se utilizaba para probar la red, repitiéndose el proceso 80 veces. Su red solamente clasificó erróneamente un ensayo, aunque es de resaltar que al considerar el motor sano, con tres y cinco barras rotas, es decir, con estados de falla bastante diferentes, se espera que la clasificación sea mucho más sencilla que por ejemplo intentar diferenciar un motor sano de uno con una barra medio rota.

Aroui *et al.* [ARO07] utilizaron una red perceptrón multicapa. Este trabajo además de las componentes de corrientes correspondientes a las frecuencias características de fallas alrededor de la fundamental, utiliza como característica para la clasificación componentes de corriente correspondientes a las frecuencias características de fallas alrededor del quinto y séptimo armónico. Variaron la cantidad de neuronas en la capa oculta para optimizar este parámetro de acuerdo al porcentaje de clasificación correcta. Realizaron 180 ensayos, un tercio con el motor sano, un tercio con una barra rota y el resto con dos barras rotas. Para entrenar el algoritmo utilizaron 120 ensayos y las restantes 60 para realizar las pruebas de desempeño. El desempeño en las pruebas va del 93 al 96 % de detecciones correctas.

Kowalski y Orłowska [KOW03] compararon dos tipos diferentes de redes neuronales, una perceptrón multicapa y un mapa auto-organizado de Kohonen. Además de barras rotas, el trabajo también considera fallas en cojinetes, desequilibrios en el suministro y cortocircuitos en el bobinado del estator. Utilizan datos del espectro de la corriente estática y de vibraciones. El trabajo sugiere, sin realizarlo, que una red del tipo Kohonen sería útil como pre-clasificador para otra red del tipo perceptrón multicapa que intente distinguir entre varios tipos de fallas.

Rafimanzelat *et al.* [RAF04] emplearon una red perceptrón multicapa con características del espectro de la corriente estática. Optimizaron la cantidad de neuronas en la capa oculta obteniendo un mejor desempeño con 20 neuronas, considerando ensayos con el motor sano y con 1, 3 y 6 barras rotas, además del motor con el anillo roto. No utilizan directamente la amplitud de las bandas características de falla por barra rota alrededor del armónico principal sino que emplean tres ratios relativos a los mismos. Primeramente consideran el ratio entre el área del armónico principal y la banda característica de falla, segundo el ratio entre la altura del armónico fundamental y los relativos a la falla y tercero el ángulo que forma el pico de la banda lateral relativa a la falla. En

Capítulo 3: Estado del arte del diagnóstico en Motores de Inducción.

estas tres características consideran el promedio entre las bandas izquierda y derecha. Antes de entrenar la red, se normalizan los datos para tener promedio cero y varianza unitaria. Obtuvieron un porcentaje de clasificación correcta del 95%.

Tabla 3.2: Resumen de los últimos artículos relacionados a la detección de fallos en motores de inducción mediante redes neuronales.

	[DON09]	[GHA10]	[KAM10]	[VAN09]	[QIN07]	[MAT10]	[GER07]	[ARO07]	[KOW03]	[RAF04]
Tipo de Red										
Perceptron Multicapa / unicapa	*	*		*	*	*		*	*	*
Regresión General			*							
Mapas auto-organizados / Kohonen		*					*		*	
Datos de Entrada Corriente										
Dominio del tiempo										
Deslizamiento					*					
Voltaje	*									
Corriente	*				*					
Potencia Activa	*				*					
Potencia Reactiva	*									
Distorsión armónica total del voltaje	*									
Distorsión armónica total de la corriente	*									
Promedio				*						
Raíz media cuadrática		*		*						
Factor de forma				*						
Asimetría		*		*						
Curtosis		*		*						
Factor de cresta				*						
Entropía de error,				*						
Estimación de entropía,				*						
Histogramas superior				*						
Máximo y mínimo valor del coeficiente de		*								
Máximo y mínimo valor del coeficiente de		*								
Histogramas inferior				*						
Segundo, tercer y cuarto momento		*								
Coefficiente de variación		*								
Dominio de frecuencia										
Frecuencias características de falla			*		*	*		*	*	*
Vector espacial de la corriente estatística			*							
Vector formado con polos del plano Z							*			
Datos de Entrada Vibraciones										
Dominio de Tiempo										
Promedio				*					*	
Raíz media cuadrática				*						
Factor de forma				*						
Dominio de frecuencia										
Raíz media cuadrática de la varianza				*						
Centro de la frecuencia				*						
Varianza de la frecuencia de raíces				*						

Del análisis de los artículos presentados se puede concluir que el tipo de red neuronal más utilizado para la detección de barras rotas en motores de inducción es el Perceptrón Multicapa, aunque hay varias referencias a la utilización del tipo mapa auto-organizado de Kohonen.

El tipo de datos de entrada más común para las redes son los provenientes del análisis del espectro de la corriente estatórica, aunque hay variedad con respecto al tipo de pre-tratamiento de los datos, como la utilización del vector espacial de la corriente o la transformada Z.

Se pueden emplear distintos tipos de transformadas, como wavelets o Hilbert, para obtener claramente las amplitudes de corriente a las frecuencias de falla características, especialmente cuando debido al deslizamiento muy bajo las frecuencias de fallo y fundamental son muy próximas.

También se utilizan datos en el dominio del tiempo de la corriente donde se propuso la utilización de diferentes valores estadísticos (medias, momentos, curtosis, etc.) la medición de valores de las tres fases y cálculo del APVD entre otros.

4 Técnicas de clasificación para el diagnóstico

4.1 Introducción

En este capítulo se describen los algoritmos empleados en la presente tesis para clasificar a los ensayos obtenidos en los estados de fallo considerados. Primeramente se exponen los métodos estadísticos más antiguos, Análisis Discriminante y Regresión Logística. Posteriormente se presenta una introducción a las Redes Neuronales, describiendo principalmente al Perceptrón Multicapa y el algoritmo de propagación del error. Finalmente se explica la teoría que da origen a los Ensamblados de Redes Neuronales. En esta última técnica se basará la metodología propuesta por la presente tesis.

4.2 Técnicas Estadísticas: Análisis Discriminante y Regresión Logística

4.2.1 Introducción

Un problema básico que se plantea cuando se trata de realizar un diagnóstico, común a muchas áreas de la ciencia, es el relacionado con la clasificación de individuos dentro de poblaciones. Dentro del término genérico “clasificación” se engloban diferentes tipos de problemas [KEN83].

- Discriminación, que supone la existencia de dos o más poblaciones de las que se han extraído las respectivas muestras de individuos. El problema que se plantea aquí es la obtención de reglas que permitan la adscripción a alguna de las poblaciones de un nuevo individuo cuya población de origen es desconocida.
- Agrupamiento (*clustering*). En este caso, se parte de una muestra de individuos de una única población y el problema consiste en clasificarlos en grupos lo más diferenciados posible.
- Disección. Implica partir de una muestra o población con el propósito de dividirla en grupos, incluso aunque se trate de una población homogénea, estableciendo para ello las correspondientes delimitaciones, sean o no naturales.

En esta tesis se utilizan dos técnicas estadísticas, el Análisis Discriminante y la Regresión Logística, de comprobada eficacia en numerosos campos de aplicación.

El Análisis Discriminante está basado en la normalidad multivariante de las variables consideradas y es óptimo bajo dicho supuesto. Sin embargo, cuando la hipótesis de normalidad sea poco realista, la Regresión Logística presenta mejores prestaciones. A continuación se resumen las principales características de ambas técnicas.

4.2.2 Análisis discriminante

4.2.2.1 Introducción

El Análisis Discriminante trata de resolver un problema de clasificación en el que se dispone de un conjunto amplio de elementos que pueden provenir de dos o más poblaciones distintas, habiéndose observado en cada elemento una variable aleatoria cuya distribución se conoce en las poblaciones consideradas. Se desea clasificar un nuevo elemento, con valores de las variables conocidas en una de las poblaciones [PEÑ02]. Es decir, se pone en relación una variable medida en escala nominal (la adscripción a grupos o variable dependiente) con un conjunto de variables medidas en escala de intervalos (las variables discriminantes o independientes). El problema básico consiste en estimar los pesos de las variables discriminantes en una combinación lineal de éstas, lo que permitiría asignar a los sujetos a sus respectivos grupos minimizando el error de clasificación. Es decir, el objetivo es determinar las variables que mejor contribuyen a discriminar entre los grupos, de tal forma que podamos predecir, en función de tales variables, la adscripción de cada individuo a un grupo determinado con un cierto grado de riesgo [GIL01]. Por lo tanto, esta técnica nos permitiría pronosticar la ubicación de un caso en alguno de los grupos determinados por una clasificación previa.

Las bases del Análisis Discriminante se encuentran en los trabajos pioneros de Karl Pearson (las primeras formulaciones de distancia entre grupos), Mahalanobis (otra medida de la distancia entre grupos) [MAH36] y Fisher (idea de una combinación lineal de variables para discriminar entre grupos) [FIS36]. A partir de ese momento, el Análisis Discriminante ha sido aplicado a múltiples campos de la actividad científica y ha ido experimentando distintos desarrollos, hasta configurar una técnica como la que en la actualidad manejamos. En [GIL01] se puede encontrar un resumen de diferentes campos en los que se ha aplicado exitosamente esta técnica.

Stevens [STE86] destaca como rasgos apreciables de esta técnica, la claridad en la interpretación que puede hacerse de los resultados, y la ventaja de que un número

amplio de variables puede ser reducido a un pequeño número de dimensiones capaces de explicar las diferencias fundamentales observadas entre los grupos.

El análisis discriminante incluye dos tipos de tareas estadísticas estrechamente relacionadas entre sí.

- **Análisis Discriminante Descriptivo.** Tiene el objetivo de determinar en qué medida un conjunto de características observadas en los individuos permite extraer dimensiones que diferencian a los grupos, y cuáles de estas características son las que presentan el mayor poder de discriminación. Las características usadas para diferenciar entre los grupos reciben el nombre de variables discriminantes.
- **Análisis Discriminante Predictivo.** El objetivo es determinar una o más ecuaciones matemáticas, denominadas funciones discriminantes, que permitan la clasificación de nuevos casos a partir de la información que se tiene sobre ellos. Estas ecuaciones combinan una serie de características o variables de tal modo que su aplicación a un caso nos permite identificar el grupo al que más se parece.

En el análisis se procede identificando una primera dimensión, que será la que mejor separa a los grupos. La segunda dimensión extraída, ortogonal a la anterior, es responsable de la mejor separación en base a la información no considerada por la primera función. De este modo se extraen sucesivas funciones, hasta agotar el número de las funciones posibles.

En principio, no existen límites para el número de variables discriminantes, salvo la restricción de que no debe ser nunca superior al número de casos en el grupo más pequeño. No obstante, Stevens [STE86] considera un problema el reducido tamaño en las muestras en comparación con el número de variables. Algunas recomendaciones sobre este punto hablan de la conveniencia de contar al menos con 20 sujetos por cada variable discriminante, si queremos que las interpretaciones y conclusiones obtenidas sean correctas. De otro modo, la estabilidad de los resultados ante la selección de muestras alternativas sería limitada. Respecto al tamaño de los grupos, no existe inconveniente en que éstos difieran en sus dimensiones. Únicamente será preciso tener en cuenta esta circunstancia a la hora de realizar la clasificación de los sujetos,

estableciendo las probabilidades a priori en función de los tamaños de los respectivos grupos, si éstos fueran desiguales.

En la exploración previa de los datos conviene prestar atención a los casos aislados (*outliers*) debido a los efectos que pueden tener sobre los resultados del análisis. Una comprobación basada en las puntuaciones típicas o en técnicas gráficas puede ser útil para detectar la existencia de este tipo de casos en cada una de las variables consideradas por separado. Para la detección de casos aislados multivariantes podría recurrirse al cálculo de la distancia de Mahalanobis de cada individuo respecto al centro de su grupo.

La idea básica que subyace en el análisis discriminante es obtener una serie de funciones lineales a partir de las variables independientes, las cuáles permitan interpretar las diferencias entre los grupos y clasificar a los individuos en alguna de las subpoblaciones definidas por la variable dependiente. Comprobado el cumplimiento de los supuestos subyacentes al modelo matemático, el primer paso en el análisis consiste en determinar las funciones discriminantes.

La función discriminante tiene como objetivo explicar la pertenencia de un individuo a uno u otro grupo en función de una combinación lineal de las variables que resultan significativas a la hora de decidir [MAR07]. Si partimos de p variables (X_1, X_2, \dots, X_p) medidas para g grupos de individuos establecidos por los valores de la variable nominal, su formato es el siguiente:

$$y_{km} = u_0 + u_1 X_{1km} + u_2 X_{2km} + \dots + u_p X_{pkm} \quad (4.1)$$

donde y_{km} es el valor de la discriminante para el caso m en el grupo k ; X_{ikm} es el valor de la variable discriminante x_i para el caso m en el grupo k ; u_i con $i = 1, 2, \dots, p$ es el conjunto de coeficientes que garantizan las características requeridas para la función.

En lo relativo al procedimiento matemático de estimación de los coeficientes para las funciones discriminantes, hay que señalar que la idea fundamental consiste en que éstas se construyen como combinaciones lineales de las variables independientes, de tal modo que den lugar a la máxima separación posible entre los grupos, al tiempo que no están correlacionadas entre sí. De acuerdo con esta idea, estas funciones habrán de ser determinadas como combinaciones lineales de las variables discriminantes que maximicen el cociente entre la variabilidad intergrupos y la variabilidad intragrupos. La

primera función hará que ese cociente sea el máximo posible para las puntuaciones. Las condiciones que deben cumplir estas funciones responden fundamentalmente a que en el orden en que van siendo obtenidas, representen la máxima diferenciación posible entre grupos. Es decir, para la primera función discriminante que determinamos, los coeficientes se obtienen de modo que valores medios alcanzados en cada grupo por la función sean entre sí lo más diferentes posibles. Para una segunda función, los coeficientes se determinan de modo que satisfagan el mismo criterio, pero además se añade la condición de que los valores obtenidos mediante la primera función no estén correlacionados con los obtenidos mediante la segunda. Las funciones discriminantes sucesivas se obtendrán de un modo similar.

El número máximo de funciones que podemos llegar a determinar será igual al número de variables discriminantes o bien al número de grupos menos uno, tomando el menor de ambos valores.

Una explicación más detallada del procedimiento matemático inherente a esta técnica puede encontrarse en [TAB83] y [HUB94].

4.2.2.2 Método paso a paso para la selección de variables

Una aplicación habitual del análisis discriminante, y así es como se va a emplear en esta tesis, es el caso en el que no se tiene la certeza de que las variables posean una suficiente capacidad de discriminación. Se parte de una lista de variables, sin poder precisar cuáles van a ser las variables discriminantes. En este sentido, el análisis discriminante puede ser usado como herramienta de exploración, que nos permitiría llegar a un buen modelo a partir de un conjunto de variables potencialmente útiles. En principio, contaríamos con una serie de variables, sin que conociéramos las que resultarán más relevantes de cara a diferenciar entre los grupos, y precisamente uno de los resultados que podemos esperar del análisis discriminante es descubrir cuáles son las variables útiles para lograr ese fin.

Ante situaciones de este tipo, determinadas variables habrían de ser eliminadas, dada su baja contribución a la discriminación de los grupos. Es el caso de las variables para las cuales los grupos alcanzan valores medios similares, y por tanto no permiten establecer una diferenciación entre ellos. O también el de variables que, aun siendo buenos discriminadores, aportan la misma información que otras y resultan redundantes.

Uno de los métodos comúnmente usados es el denominado método paso a paso (*stepwise* en la literatura anglosajona). Este método puede desarrollarse en dos direcciones:

- Método de selección paso a paso hacia adelante (*forward*). La primera variable que entra a formar parte del análisis es la que maximiza la separación entre grupos. A continuación, se forman parejas entre esta variable y las restantes, de modo que encontremos la pareja que produce la mayor discriminación. La variable que contribuye a la mejor pareja es seleccionada en segundo lugar. Con ambas variables seleccionadas y las restantes podrían formarse triadas de variables para determinar cuál de éstas resulta más discriminante. De este modo quedaría seleccionada la tercera variable. El proceso continuaría hasta que todas las variables hayan sido seleccionadas o las variables restantes no supongan un suficiente incremento en la capacidad de discriminación.
- Método de selección paso a paso hacia atrás (*backward*). Todas las variables son consideradas inicialmente, y van siendo excluidas una a una en cada etapa, eliminando del modelo aquéllas cuya supresión produce el menor descenso en la discriminación entre los grupos.

Frecuentemente, las direcciones hacia adelante y hacia atrás se combinan en la aplicación del método *stepwise*. Se partiría de una selección hacia adelante de variables, aunque revisando tras cada paso el conjunto de variables resultantes, por si pudiera excluirse alguna de ellas. Esto puede ocurrir cuando la incorporación de una variable supone que alguna de las anteriormente consideradas resulte redundante.

El método *stepwise* conduce a la selección de un conjunto óptimo de variables de cara a la discriminación. Como criterio de selección es preciso utilizar alguna medida de la discriminación. Los diversos criterios utilizados suelen conducir a resultados similares, aunque no siempre. Cuál de estos criterios resulta más adecuado es algo que depende de la situación concreta en que se emplean. Los más habituales son [PAR05]:

- Criterio basado en la minimización de la *lambda* de Wilks: El estadístico *lambda* de Wilks expresa la proporción de variabilidad total no debida a las diferencias entre los grupos. Wilks, basándose en el principio de razón de verosimilitud generalizada (según el cual la varianza generalizada de un espacio multivariante

puede ser calculada mediante el determinante de la matriz de dispersión), planteó el estadístico λ , definido como:

$$\lambda = \frac{|S|}{|T|} = \frac{\text{Suma de cuadrados intragrupos}}{\text{Suma de cuadrados total}} \quad (4.2)$$

donde S es la matriz de varianzas-covarianzas *combinada*, calculada a partir de las matrices de varianzas-covarianzas de cada grupo, y T es la matriz de varianzas-covarianzas *total*, calculada sobre todos los casos como si pertenecieran a un único grupo. Cada variable independiente candidata a ser incluida en el modelo se evalúa mediante un estadístico F_{cambio} que mide el cambio que se produce en el valor de la *lambda* de Wilks al incorporar cada una de las variables al modelo. Obtenido el valor del estadístico F_{cambio} para cada variable, se incorpora al modelo la variable a la que le corresponde el mayor valor F_{cambio} (o, lo que es lo mismo, la que produce el mayor cambio en la *lambda* de Wilks):

$$F_{\text{cambio}} = \left(\frac{n-g-p}{g-1} \right) \left(\frac{1 - \lambda_{p+1} / \lambda_p}{\lambda_{p+1}} \right) \quad (4.3)$$

donde n es el número de casos válidos, g es el número de grupos, λ_p es la *lambda* de Wilks que corresponde al modelo antes de incluir la variable que se está evaluando y λ_{p+1} es la *lambda* de Wilks que corresponde al modelo después de incluir esa variable

- Criterio basado en la distancia de Mahalanobis: Se incorpora en cada paso la variable que maximiza la distancia de Mahalanobis entre los dos grupos más próximos. La distancia multivariante entre los grupos a y b se define como:

$$H_{ab}^2 = (n-g) \sum_{i=1}^p \sum_{j=1}^p w_{ij}^* (\bar{X}_i^{(a)} - \bar{X}_i^{(b)}) (\bar{X}_j^{(a)} - \bar{X}_j^{(b)}) \quad (4.4)$$

donde n es el número de casos válidos, g es el número de grupos, $\bar{X}_i^{(a)}$ es la media del grupo a en la i -ésima variable independiente, $\bar{X}_i^{(b)}$ es la media del grupo b en la i -ésima variable independiente, y w_{ij}^* es un elemento de la inversa de la matriz de varianzas- covarianzas intra-grupos.

- Criterio basado en la F intergrupos. Se incorpora en cada paso la variable que maximiza la menor razón F para las parejas de grupos. El estadístico F utilizado es la distancia de Mahalanobis ponderada por el tamaño de los grupos:

$$F = \frac{(n-p-1)}{p(n-2)(n_1+n_2)} H_{ab}^2 \quad (4.5)$$

- Criterio basado en la Varianza no explicada. Utiliza como criterio de inclusión la suma de la variación entre todos los pares de grupos no explicada por las variables ya incluidas en el modelo. Se incorpora al modelo la variable que minimiza la cantidad de varianza no explicada. La cantidad de varianza explicada por el modelo, R^2 , es proporcional, en una constante c , a la distancia H de Mahalanobis (ver más abajo):

$$R^2 = cH_{ab}^2 \quad (4.6)$$

Para calcular la cantidad de varianza no explicada se utiliza el estadístico R :

$$R = \sum_{a=1}^{g-1} \sum_{b=a+1}^g \frac{4}{4 + H_{ab}^2} \quad (4.7)$$

donde g es el número de grupos, y a y b son dos grupos cualesquiera.

- Criterio basado en la V de Rao: El estadístico V de Rao es una transformación de la traza de Lawley- Hotelling que es directamente proporcional a la distancia entre los grupos. Al utilizar este criterio, la variable que se incorpora al modelo es aquella que produce un mayor incremento en el valor de V :

$$V = (n_k - g) \sum_{i=1}^p \sum_{j=1}^p w_{ij}^* \sum_{k=1}^g (\bar{X}_i^{(k)} - \bar{X}_i)(\bar{X}_j^{(k)} - \bar{X}_j) \quad (4.8)$$

donde p es el número de variables en el modelo, g es el número de grupos, n_k es el número de casos válidos del grupo k , $\bar{X}_i^{(k)}$ es la media del grupo k en la i -ésima variable, \bar{X}_i es la media de todos los grupos en la i -ésima variable, y w_{ij}^* es un elemento de la inversa de la matriz de varianzas-covarianzas intra-grupos.

Un análisis más detallado de estos procedimientos puede encontrarse en [GIL01] y [PAR05].

4.2.2.3 Matriz de clasificación

Si mediante el análisis discriminante conseguimos clasificar a los sujetos, podemos cuestionarnos la bondad del procedimiento de clasificación. Una forma de valorar la bondad de la clasificación realizada es aplicar el procedimiento a los casos para los que conocemos su grupo de adscripción, y comprobar si coinciden el grupo predicho y el grupo observado. El porcentaje de casos correctamente clasificados indicará la corrección del procedimiento.

La matriz de clasificación, también denominada matriz de confusión, permite presentar para los casos observados en un grupo, cuántos de ellos se esperaban en ese grupo y cuántos en los restantes. De esta forma, resulta fácil constatar qué tipo de errores de clasificación se producen. La estructura de la matriz de clasificación sería la mostrada en la Tabla 4.1, donde cada valor n_{ij} representa el número de casos del grupo i que tras aplicar las reglas de clasificación son adscritos al grupo j . Los valores situados en la diagonal descendente constituyen, por tanto, el número de casos que han sido correctamente clasificados.

Tabla 4.1. Estructura de la matriz de confusión.

	Grupo 1	Grupo 2	Grupo 3	Total
Grupo 1	n_{11}	n_{12}	n_{13}	$n_{.1}$
Grupo 2	n_{21}	n_{22}	n_{23}	$n_{.2}$
Grupo 3	n_{31}	n_{32}	n_{33}	$n_{.3}$
Total	$n_{.1}$	$n_{.2}$	$n_{.3}$	n

En la matriz de clasificación, también conocida como matriz de confusión, es frecuente encontrar estos valores en forma de porcentajes. Si el porcentaje de casos correctamente clasificados es alto, cabe esperar que las funciones discriminantes también proporcionen buenos resultados a la hora de predecir el grupo al que se adscribirá cualquier nuevo sujeto perteneciente a la misma población de donde fue extraída la muestra. Este porcentaje puede ser tomado como una medida, no solo de la bondad de la clasificación, sino también de las diferencias existentes entre los grupos; si la clasificación es buena se deberá a que las variables discriminantes permiten diferenciar entre los grupos.

Un problema aparejado a la valoración del error de clasificación se encuentra en que el porcentaje de casos correctamente clasificados representa una estimación optimista del

resultado que se logra en la población. Ello es consecuencia de que el modelo de discriminación construido se ajustará a la muestra que sirvió para obtenerlo mejor que a cualquier otra muestra extraída de la población. Se han propuesto vías para obtener un mejor estimador del error de clasificación, algunas de las cuales son las recogidas en [STE86]:

a) División aleatoria de la muestra en dos submuestras. Una solución podría consistir en utilizar una parte de la muestra para extraer las funciones discriminantes, y comprobar la bondad de la clasificación obtenida aplicándolas a los casos de la otra muestra. De este modo se refleja con mayor realismo la efectividad de la función, aunque el procedimiento tiene como inconveniente la necesidad de contar con muestras suficientemente grandes y la infrutilización de buena parte de la información disponible para calcular las funciones discriminantes.

b) Método *jackknife*, debido a Lachenbruch [LAC67]. También denominado método de sacar uno, consiste en extraer un caso de la muestra y obtener las funciones discriminantes a partir de los $n-1$ casos restantes, utilizando el caso extraído para comprobar la correcta clasificación del mismo al aplicarle las funciones discriminantes obtenidas. El proceso habría de repetirse eliminando cada vez un caso distinto. De este modo, el caso que va a ser clasificado no toma parte en la construcción de las funciones. Este segundo procedimiento sería adecuado con muestras de tamaño pequeño o medio, pues para muestras grandes, además de ser muy costoso, conduce a resultados poco diferentes a la clasificación original [TAB83].

La magnitud del porcentaje de casos correctamente clasificados podría valorarse teniendo en cuenta el porcentaje que obtendríamos si la asignación entre los grupos se hubiera hecho al azar. En una asignación al azar entre dos grupos, cabe esperar que el 50% de los casos estén correctamente clasificados; en cambio, si los grupos fueran cuatro, cabría esperar un 25% de asignaciones correctas. Es evidente que un 60% de casos correctamente clasificados no tiene el mismo significado cuando existen dos grupos que cuando trabajamos con cuatro, pues en el primero de ellos nos movemos en niveles muy próximos a la distribución al azar de los casos entre los grupos. Una medida del error de clasificación, teniendo en cuenta el número de grupos, es la que conseguimos mediante el estadístico *tau*, cuya expresión es:

$$\tau = \frac{n_c - \sum_{i=1}^g p_i n_i}{n - \sum_{i=1}^g p_i n_i} \quad (4.9)$$

Donde n_i es el número de casos correctamente clasificados y el valor p_i corresponde a la probabilidad a priori de pertenencia a un grupo. En esta expresión, el término calculado como sumatorio representaría el total de casos correctamente clasificados si la distribución entre los grupos se hubiera hecho al azar. El valor máximo de τ es 1, que se alcanzaría cuando no hay errores de predicción. El resultado indicaría la proporción en que se reduce el error de clasificación cometido frente al error que se cometería en una clasificación al azar.

4.2.3 Regresión Logística

Los métodos de regresión se han convertido en una parte fundamental de cualquier análisis de datos que pretenda describir la relación entre una variable respuesta y una o más variables explicativas. El modelo de regresión lineal es un procedimiento estándar que se viene aplicando desde hace muchos años en muchos campos diferentes, en aquellos casos en los que la variable de salida es continua. Sin embargo, en muchas situaciones prácticas la variable de salida es discreta tomando dos o más valores posibles. Un caso habitual es el de encontrarse con una variable de salida dicotómica (dos posibles valores) correspondiendo a situaciones tales como “fallo – no fallo”, “enfermo – sano”,... En los últimos años, el modelo de regresión logística se ha convertido en el procedimiento estándar en esta situación [HOS00] pues, en esas circunstancias, el modelo de regresión lineal presenta diversos problemas tales como no linealidad y no-normalidad, que llevan a una estimación ineficiente [PAM00].

La principal razón de la popularidad de la regresión logística es debida a las prestaciones que ofrece la utilización de la función logística que describe la naturaleza matemática del método logístico [KLE02]. Esta función, $f(z)$, está representada en la Fig. 4.1 y responde a la ecuación (4.10), siendo su rango entre 0 y 1, lo que presenta la ventaja de poder equipararse a una probabilidad (que puede representar, por ejemplo, el riesgo de que un individuo presente una enfermedad, o un equipo esté en estado de fallo).




Figura 4.1. Función logística.

$$f(z) = \frac{1}{1 + e^{-z}} \quad (4.10)$$

De esta forma, siempre se asegura que la estimación estará comprendida entre 0 y 1, lo que no es siempre cierto para otros modelos posibles, razón por lo cual este modelo es el preferido cuando se trata de estimar una probabilidad. Además, tal como se puede observar en la Fig. 4.1, según empieza a aumentar el valor de z , el valor de $f(z)$ se mantiene cercano a 0. Posteriormente experimenta un rápido y significativo aumento hacia 1, para al final seguir una tendencia asintótica más suave hacia 1. Esta forma de S que sigue la función conlleva una ventaja práctica en muchas aplicaciones puesto que, si se considera a la variable z como un índice que combina las contribuciones de varios factores de riesgo, y $f(z)$ representa el riesgo para un determinado valor de z , entonces el efecto de z sobre un riesgo individual es mínimo hasta que un determinado umbral es alcanzado, para, a partir de ahí, aumentar rápidamente sobre un cierto rango de valores intermedios para después permanecer alto (casi 1) una vez que z es suficientemente grande [KLE02]. Esta característica es especialmente útil en epidemiología, aplicándose la idea de umbral a diferentes condiciones de enfermedad, y teniendo en cuenta la naturaleza multivariable de una investigación epidemiológica, por lo que en este campo la regresión logística está teniendo una rápida aceptación.

Dentro del rango de una muestra, la regresión lineal puede aproximar una relación curvilínea, tomando la media de sucesivas pendientes implícitas en la curva. Sin embargo, la relación lineal subestima la dependencia real en la parte media de la curva y la sobreestima en los extremos, a no ser que la variable independiente tome valores sólo en una región donde la curva sea cuasi-lineal [PAM00].

La transformación logística puede entenderse como la linealización de la relación no-lineal intrínseca entre las variables dependientes X y la variable independiente. Se

esperaría que el mismo cambio en X tuviera un impacto menor en los extremos que en la parte media. Dado que la transformación expande o estrecha las probabilidades en los valores extremos relativo a los valores intermedios, el mismo cambio en X produce similares efectos a lo largo de todo el rango de la transformación.

Para obtener el modelo logístico a partir de la función logística, si escribimos z como la suma lineal de las variables X_i que representan variables independientes (4.11) siendo α y β_i parámetros a determinar. Es decir, z es un índice que combina las variables X_i .

$$z = \alpha + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k \quad (4.11)$$

Si se substituye esta expresión lineal por la fórmula de $f(z)$ se obtiene (ec. 4.12)

$$f(z) = \frac{1}{1 + e^{-z}} = \frac{1}{1 + e^{-\sum \alpha \beta_i X_i}} \quad (4.12)$$

En realidad, para ver esta expresión como un modelo matemático, hay que situarlo en un contexto epidemiológico. Si se han observado unas variables independientes X_1, X_2, X_k en un grupo de sujetos, en los que también se ha determinado un estado de la enfermedad, como 1 si "con la enfermedad", o 0 si "sin enfermedad", y queremos utilizar esta información para describir la probabilidad de que se desarrollará la enfermedad durante un período definido de estudio, por ejemplo T_0 a T_1 , en un individuo libre de enfermedad con los valores de la variable independiente que se mide en T_0 .

La probabilidad a modelar puede ser denotada por la declaración de probabilidad condicional:

$$P(D = 1 | X_1, X_2, \dots, X_k) = P(X) \quad (4.13)$$

El modelo se define como logístico si la expresión para la probabilidad de desarrollar la enfermedad es:

$$P(X) = \frac{1}{1 + e^{-\sum \alpha \beta_i X_i}} \quad (4.14)$$

Por lo tanto, si conociéramos los parámetros α y β_i y determinásemos los valores X_1, \dots, X_k , para un determinado individuo libre de la enfermedad, podemos usar esta fórmula para obtener la probabilidad de que este individuo pueda desarrollar la enfermedad a lo largo de un determinado intervalo de tiempo.

4.3 Redes Neuronales

4.3.1 Introducción

Una gran cantidad de avances se han producido en el área de Inteligencia Artificial, algunos de ellos inspirados por las redes neuronales biológicas. Investigadores de varias disciplinas científicas han desarrollado redes neuronales artificiales, ANN (*Artificial Neural Network*), para resolver una gran variedad de problemas tales como reconocimiento de patrones, predicción, optimización, memoria asociativa o control. Aunque todos estos problemas también han inspirado resoluciones más tradicionales, las ANNs proveen alternativas más versátiles que pueden ser de gran ayuda en muchos casos. Inspiradas en las redes neuronales biológicas, las ANNs son sistemas computacionales constituidos por un gran número de procesos simples con muchas conexiones que intentan implementar algunos principios organizativos que se cree son utilizados por el cerebro humano [JAI96]. En la Tabla 4.2 se observa una comparación entre las características de las redes neuronales biológicas y los computadores de arquitectura Von Neumann.

Tabla 4.2. Comparación entre redes neuronales biológicas y artificiales.

	Computadoras	Sistemas neuronales biológicos
Procesador	Complejo	Simple
	Alta velocidad	Baja velocidad
	Uno o pocos	Una gran cantidad
Memoria	Separada del procesador	Integrada al procesador
	Localizada	Distribuida
	No vinculada al contenido	Vinculada al contenido
Computo	Centralizado	Distribuido
	Secuencial	Paralelo
	Guardado en programas	Autoaprendizaje
Fiabilidad	Muy vulnerable	Robusta
Experticia	Manipulación numérica y simbólica	Problemas perceptuales
Ambiente de operación	Bien definido	Escasamente definido
	Bien restringido	Sin restricciones

El presente apartado está organizado de la siguiente forma: primeramente se dará una pequeña reseña histórica de las ANNs, seguidamente se describirá la neurona biológica

para luego explicar su contrapartida artificial. A continuación se explicará en qué consiste una ANN y cómo está constituida para posteriormente describir sus formas de aprendizaje. Seguidamente, se describirán las formas de conexión entre neuronas y los tipos de ANN más utilizadas en el diagnóstico de fallas. Finalmente se describirá el ensamble de redes neuronales.

4.3.2 Reseña histórica

La investigación en ANN ha experimentado tres periodos de intensa actividad [RIC94]. El primer pico acaeció en la década de 1940 debido al trabajo pionero de McCulloch y Pitts [MCC43]. El segundo periodo ocurrió en los años 1960s con el teorema de la convergencia del Perceptron de Rosenblatt [ROS62] y el trabajo de Minsky y Papert mostrando las limitaciones del Perceptron simple [MIN69]. El resultante estancamiento en la investigación en ANNs duró 20 años. A principio de la década de 1980 las ANN recibieron un renovado interés de parte de la comunidad científica. Los trabajos más importantes detrás de este resurgir incluyen la aproximación energética de Hopfield en 1982 [HOP82] y el algoritmo de aprendizaje backpropagation para redes Perceptron multicapa primeramente propuesto por Werbos [WER74], reinventado varias veces y luego popularizado por Rumelhart et al. [RUM86].

4.3.3 La Neuron Biológica

En general, una neurona consta de un cuerpo celular más o menos esférico de 5 a 10 micras de diámetro, del que sale una rama principal denominada axón y varias ramas más cortas llamadas dendritas. A su vez, el axón puede producir ramas en torno a su punto de arranque, y con frecuencia se ramifica extensamente cerca de su extremo (Fig. 4.2) [ISA04].

Una de las características que diferencian a las neuronas del resto de células vivas 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 transporta esas señales a los terminales axónicos, que se encargan de distribuir información a un nuevo conjunto de neuronas. Por lo general, una neurona recibe información de miles de otras neuronas y, a su vez, envía información a miles de neuronas más. Se calcula que en el cerebro humano existen del orden de 10^{15} conexiones [PIN01].




Figura. 4.2 Esquema de una neurona biológica [ISA04].

4.3.4 Red Neuronal Artificial

Una Red de Neuronas Artificiales, ANN, es un paradigma de procesamiento de información inicialmente inspirado en el modo en el que lo hace el cerebro. El elemento clave de este paradigma es su estructura. Las ANNs están compuestas por un cierto número de elementos de procesamiento o *neuronas* que trabajan al unísono para resolver un problema específico [PAL08]. Las redes neuronales actuales se basan en el modelo matemático de neurona propuesto por McCulloch y Pitts en 1943 [MCC43]. En dicho modelo (Fig. 4.3) cada neurona recibe un conjunto de entradas $\{x_1, x_2, \dots, x_D\}$ y devuelve una única salida y . Además, dentro de una ANN existen numerosas conexiones entre las distintas neuronas que la conforman. Estas conexiones simulan las conexiones interneuronales del cerebro y, al igual que éstas, pueden establecerse con mayor o menor intensidad. En el caso de las ANNs esta intensidad la determinan los *pesos sinápticos* (o simplemente *pesos*). De este modo, cada entrada x_i de una neurona se encuentra afectada por un peso w_i .




Figura 4.3 Modelo neuronal de McCulloch-Pitts [PAL08].

El primer paso para obtener la salida y de la neurona es calcular la suma ponderada a de las entradas, llamada *activación* de la neurona [PAL08]:

$$a = \sum_{i=1}^D w_i x_i + w_o \quad (4.15)$$

donde w_o es un *umbral* o *sesgo* (en algunos textos se emplea la nomenclatura inglesa *bias*) que se utiliza para compensar la diferencia entre el valor medio de las entradas, sobre todo el conjunto de entrenamiento, y el correspondiente valor medio de las salidas deseadas. Posteriormente, a partir de este valor a se obtiene la salida y de la neurona mediante la aplicación de una función, llamada *función de activación* o *de transferencia* $g(a)$, es decir:

$$y = g(a) = g\left(\sum_{i=1}^D w_i x_i + w_o\right) = g\left(\sum_{i=0}^D w_i x_i\right) \quad (4.16)$$

donde, como se observa, es posible tratar el umbral w_o como un peso más si se supone una entrada añadida x_o con un valor fijo de 1 (Fig. 4.3). Finalmente, también es posible reescribir esta ecuación en notación vectorial como $g(a) = g(w^T x)$, si tomamos w como el vector de pesos y x como el vector de entradas a la red.

La función de transferencia empleada en este modelo básico de McCulloch-Pitts es la función escalón definida por la ecuación:

$$g(a) = \begin{cases} 0 & \text{cuando } a < 0 \\ 1 & \text{cuando } a > 0 \end{cases} \quad (4.17)$$

y que se puede ver en la Fig. 4.4 a. Como veremos, en los modelos actuales se escogen otro tipo de funciones, normalmente monótonas y derivables. Las más comunes, cuyas formas se muestran también en la Fig. 4.4, son la función lineal,

$$g(a) = a \quad (4.18)$$

la sigmoidea

$$g(a) = \frac{1}{1 + e^{-a}} \quad (4.19)$$

la tangente hiperbólica (*tanh*)

$$g(a) = \tanh(a) = \frac{e^a - e^{-a}}{e^a + e^{-a}} \quad (4.20)$$

y la gaussiana

$$g(a) = \exp\left(-\frac{(a-\mu)^2}{2\sigma^2}\right) \quad (4.21)$$

Al número de neuronas que componen una ANN y a la forma en cómo están conectadas entre sí, se le conoce como *topología* de la red. A lo largo de este apartado veremos ciertos tipos de ANN que implican formas preestablecidas de ordenar y conectar las neuronas dentro de la red [PAL08].




Figura 4.4: Principales funciones de transferencia utilizadas [PAL08].

4.3.5 Métodos de aprendizaje: supervisado o no supervisado

Aprendizaje supervisado: Este tipo de aprendizaje se utiliza para modelar la correspondencia entre un conjunto de N ejemplos o patrones de entrada $\{x_1, x_2, \dots, x_N\}$ y las salidas deseadas $\{t_1, t_2, \dots, t_n\}$, minimizando para ello la función de error que mide la diferencia existente entre estas salidas y las obtenidas por la red $\{y_1, y_2, \dots, y_n\}$ [PAL08]. Es decir, en el aprendizaje supervisado se proporciona al algoritmo de conjunto de datos de muestra o entrenamiento un valor de salida esperado de la red.

Aprendizaje no supervisado. ¿Puede aprender algo útil la red si no se le proporciona un conjunto de entrenamiento con la salida deseada de cada entrada? La respuesta es positiva [RIC94]. Esta forma de aprendizaje se denomina *aprendizaje no supervisado* (*unsupervised learning*) ya que no se necesita ningún “profesor” que muestre la salida deseada a la red con cada entrada. Dado un conjunto de entradas, a la red se le permite “jugar” con ellos para intentar descubrir regularidades y relaciones entre las diferentes partes de las entradas.

El aprendizaje se produce frecuentemente a través de alguna noción sobre qué características del conjunto de entrada son importantes. Sin embargo, con frecuencia esto no es conocido de antemano. El aprendizaje no supervisado se puede utilizar como un módulo descubridor de características, o agrupador de entradas similares, que preceda a un aprendizaje supervisado [PAL08]. Redes que implementan este tipo de

aprendizaje son los Mapas Autoorganizados (Redes de Kohonen) y las Redes Neuronales Deep Learning, entre otras.

4.3.6 Redes neuronales para aprendizaje supervisado

En esta sección se presentan las arquitecturas más comunes utilizadas en redes de neuronas basadas en aprendizaje supervisado pues ese es el tipo de red neuronal utilizado en la presente Tesis.

4.3.6.1 Tipos básicos de problemas

Existen dos tipos básicos de problemas de aprendizaje supervisado que una ANN puede tratar de resolver [PAL08]:

- a) problemas de clasificación: el objetivo consiste en crear un procedimiento mediante el cual un nuevo caso representado por unos atributos observados o *características* que constituyen los datos de entrada a la ANN, se asigne a una de entre un conjunto de clases predefinidas. A la construcción de estos clasificadores también se le conoce como *reconocimiento de patrones*
- b) y problemas de regresión: son problemas de *ajuste de funciones*. Es decir, se trata de obtener un número en función de los atributos de entrada a la red o, lo que es lo mismo, se trata de encontrar una función continua de ciertas variables.

4.3.6.2 El perceptrón multicapa

Es una de las redes más utilizadas para resolver problemas de aprendizaje supervisado. Las limitaciones de las redes de una sola capa hicieron que se plantease la necesidad de implementar redes en las que se aumentase el número de capas introduciendo capas intermedias entre la capa de entrada y la capa de salida, de manera que se pudiese implementar cualquier función con el grado de precisión deseado. La función que cumple dicha capa intermedia es tratar de realizar una proyección en la que resulten separables linealmente los patrones de entrada de manera que la unidad de salida pueda realizar una clasificación correcta. Surge así el perceptrón Multicapa, en adelante MLP (*MultiLayer Perceptron*), cuya arquitectura mostrada en la Fig.4.5, incluye una o varias capas intermedias de unidades procesadoras, también denominadas *capas ocultas* porque no tienen conexiones con el exterior [PAL08].

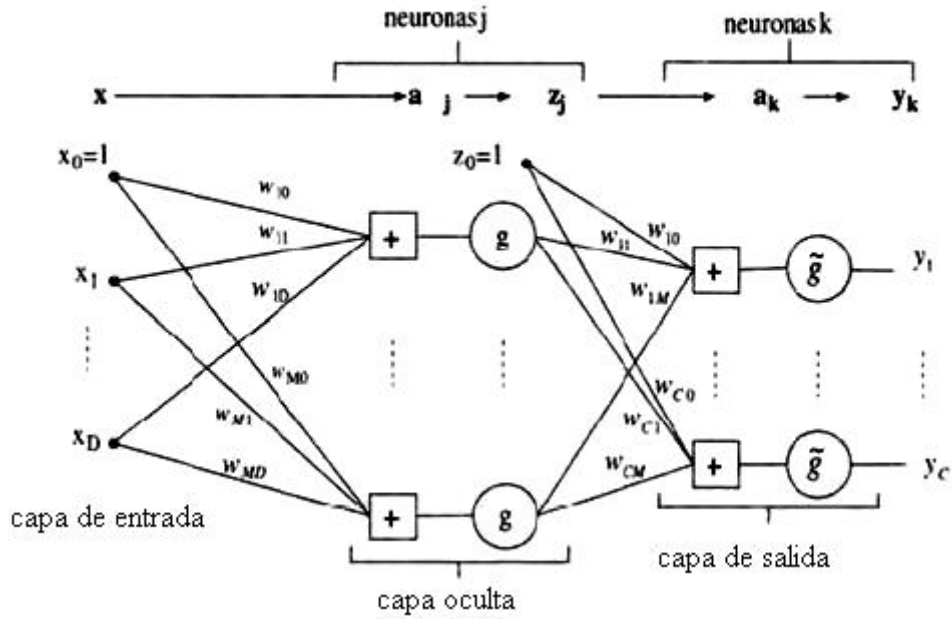


Figura 4.5: Arquitectura de un perceptrón multicapa con una capa oculta [PAL08].

Aquí, simplemente consideraremos un MLP con una única capa oculta tal y como se representa en la Fig. 4.5, si bien el hecho de añadir más capas sólo supone repetir las operaciones que se van a exponer a continuación. Así, dicho MLP consta de D entradas, M neuronas en su capa oculta y C unidades de salida. El nivel de activación a_j de la neurona j de la capa oculta se calcula como una combinación lineal de las D entradas x_i que recibe sobre la que, tras aplicar una función de transferencia g se obtiene la salida z_j de dicha neurona [PAL08]:

$$z_j = g(a_j) = g\left(\sum_{i=0}^D w_{ij}x_i\right) \quad (4.22)$$

donde w_{ij} es el peso asociado a la neurona j y la entrada x_i .

De manera similar, cada salida de la red se obtiene como una suma ponderada de las salidas de las unidades de la capa oculta, sobre la que se aplica una función de transferencia, es decir, la salida de la neurona k viene dada por:

$$y_k = \tilde{g}(a_k) = \tilde{g}\left(\sum_{j=0}^M w_{kj}z_j\right) = \tilde{g}\left(\sum_{j=0}^M w_{kj}g\left(\sum_{i=0}^D w_{ji}x_i\right)\right) \quad (4.23)$$

Es importante destacar que las funciones de transferencia g y \tilde{g} no necesariamente deben ser iguales, por ello la notación que se emplea es diferente.

4.3.6.2.1 Algoritmo de retropropagación del error

El MLP basa el aprendizaje de sus pesos en una regla de ajuste del error, esto es, trata de determinar los pesos de las conexiones sinápticas de manera que las salidas de la red sean lo más próximas posibles a las salidas. A continuación se mostrará cómo el método de descenso del gradiente es empleado para ajustar los pesos de la red. Dicho ajuste se realiza comenzando por la capa de salida, según el error cometido, y propagando este error a las capas anteriores, hasta llegar a la capa de las unidades de entrada, de ahí que se denomine algoritmo de retropropagación del error (*backpropagation algorithm*). Básicamente consiste en dos fases que se repiten hasta conseguir minimizar el error [PAL08]:

- En la primera fase, o paso hacia adelante, se aplica la (4.22) para un conjunto de pesos dado, a fin de determinar las salidas correspondientes a estas entradas. Normalmente, en la primera iteración del algoritmo se parte de un conjunto de pesos con un valor inicial pequeño aleatorio.
- En la siguiente fase, o paso hacia atrás, los pesos de la red se recalculan de acuerdo con una regla de ajuste del error. Es decir, se calcula el valor de la función de error que compara la respuesta actual de la red y la respuesta deseada, y este error se propaga hacia atrás.

A continuación se explica este último paso en detalle. Para ello, en esta sección, se asumirá como función de error el ECM, error medio cuadrático, una de las más ampliamente utilizadas. Así, para cada patrón x^n se tiene la siguiente función de error:

$$E^n = \frac{1}{2} \sum_{k=0}^C (e_k^n)^2 = \frac{1}{2} \sum_{k=0}^C (y_k^n - t_k^n)^2 \quad (4.24)$$

donde el factor $1/2$, que no altera el resultado de la función, se introduce para facilitar los cálculos posteriores, y_k^n es la salida de la red y t_k^n la salida deseada:

Supongamos que nos encontramos en la iteración n del algoritmo de aprendizaje en el que se ha introducido un patrón x^n . El algoritmo de retropropagación corrige el peso sináptico w_{kj} añadiéndole un incremento Δw_{kj} . En este caso, el incremento es proporcional al gradiente $\delta E / \delta w_{kj}$ dado que, si consideramos la superficie de error que se forma al representar E junto el espacio de pesos, este gradiente determina la dirección

de la búsqueda en este espacio para obtener el valor del peso w_{kj} que conduce a un mínimo de E . De acuerdo con la regla de la cadena para derivadas parciales, este gradiente se representa como [PAL08]:

$$\frac{\delta E}{\delta w_{kj}} = \frac{\delta E}{\delta e_k} \frac{\delta e_k}{\delta y_k} \frac{\delta y_k}{\delta a_k} \frac{\delta a_k}{\delta w_{kj}} = -e_k \tilde{g}'(a_k) z_j \quad (4.25)$$

que se obtiene tras derivar las ecuaciones (4.24), (4.23), (4.22) y $a_k = -\sum_{j=0}^M w_{kj} z_j$ con respecto a las variables indicadas, esto es:

$$\frac{\delta E}{\delta e_k} = e_k \quad \frac{\delta e_k}{\delta y_k} = -1 \quad \frac{\delta y_k}{\delta a_k} = \tilde{g}'(a_k) \quad \frac{\delta a_k}{\delta w_{kj}} = z_j \quad (4.26)$$

Teniendo en cuenta que el gradiente local δ de una neurona k se define como:

$$\delta_k = \frac{\delta E}{\delta e_k} \frac{\delta e_k}{\delta y_k} \frac{\delta y_k}{\delta a_k} = -e_k \tilde{g}'(a_k) \quad (4.27)$$

se tiene que el incremento que se debe aplicar al peso w_{kj} es:

$$\Delta w_{kj} = \eta \frac{\delta E}{\delta w_{kj}} = -\delta_k z_j \quad (4.28)$$

donde η es el ratio de aprendizaje. Esta ecuación señala que, para obtener el incremento necesario, únicamente es necesario multiplicar el valor de δ para la unidad de salida de la neurona por el valor z de la unidad de entrada de la neurona.

Para calcular el gradiente local δ_k de una neurona que no esté en la capa de salida, el error de la misma tendrá que determinarse recursivamente considerando todas las neuronas de la capa de salida a las que está conectada dicha neurona k . Se denomina j a la neurona de la capa oculta de la que se desea estimar el gradiente, y k a cada una de las neuronas de salida. El gradiente local δ_j para una neurona en la capa oculta se define como [PAL08]:

$$\delta_j = \frac{\delta E}{\delta z_j} \frac{\delta z_j}{\delta a_j} = -\frac{\delta E}{\delta z_j} \tilde{g}'(a_j) = g'(a_j) \sum_k \delta_k w_{kj} \quad (4.29)$$

y el ajuste del peso w_{ji} , de modo similar a la ecuación (4.28), viene dado por:

$$\Delta w_{ji} = \eta \delta_j x_i \quad (4.30)$$

Es importante recordar que el error que se ha calculado es el error cometido al introducir el patrón n -ésimo. Por ello, los pesos se actualizan cada vez que se le presenta un nuevo patrón x^n a la red. Otra opción existente consiste en calcular las derivadas una vez que se han proporcionado a la red todos los patrones (aprendizaje por lotes o *batch*), de este modo los pesos de la primera capa se actualizarían como:

$$\Delta w_{ji} = -\eta \sum_n \delta_j^n x_i^n \quad (4.31)$$

con expresiones análogas para los pesos de la segunda capa. Una de las ventajas de este algoritmo es su eficiencia computacional, ya que está demostrado que el coste computacional es $O(W)$, donde W es el número total de pesos y umbrales [PAL08].

4.3.6.2.2 Determinación de la topología del Perceptrón Multicapa

En 1989, Cybenko [CYB89] demostró que el MLP con una sola capa oculta y un número suficiente de neuronas en dicha capa, con funciones de transferencia \tilde{g} sigmoideas, y una función de transferencia en la capa de salida lineal es capaz de aproximar cualquier función continua f de R^D en R con el grado de precisión deseado. Asimismo, Cybenko también demostró que dicho perceptrón es un clasificador universal. Por lo tanto, cuando se aplica el perceptrón multicapa a un problema real, y no se consigue la precisión deseada, es porque no se ha conseguido una determinación adecuada de los pesos de la red, o no se ha utilizado el número apropiado de neuronas en la capa oculta. Sin embargo, no hay un procedimiento sencillo ni general para determinar la topología adecuada del MLP. Normalmente, se comienza por redes de tamaño reducido, dado que su entrenamiento es más rápido, y se va incrementando paulatinamente el número de neuronas hasta alcanzar una topología que presente el comportamiento deseado [PAL08].

4.3.6.2.3 Métodos avanzados de aprendizaje

El algoritmo básico de retropropagación del error para el entrenamiento de MLP utiliza la información del gradiente proporcionado por la derivada de una función de error respecto a los pesos para encontrar los valores de éstos que proporcionan un mínimo de la función de error. A pesar de su utilidad, este método presenta varios problemas [PAL08]:

Capítulo 4: Técnicas de clasificación para el diagnóstico.

- 1) La función de error a optimizar normalmente presenta varios mínimos locales. Así, simplemente con utilizar distintos valores iniciales para los pesos podremos obtener soluciones finales diferentes tras el entrenamiento.
- 2) La convergencia del proceso de aprendizaje hacia el mínimo puede ser lenta.

Para resolver estos problemas han surgido otros métodos de aprendizaje, la mayoría basados en modificaciones del algoritmo original de retropropagación. Algunos de los más utilizados son [PAL08]:

- *Métodos basados en mínimos cuadrados lineales.* Se basan igualmente en la minimización del ECM pero lo hacen entre la señal a que recibe la neurona de salida antes de aplicar la función de activación no lineal y una versión de la salida deseada modificada adecuadamente. Con ello se consigue eliminar en algunos casos, y reducir en otros, las iteraciones necesarias en el entrenamiento [CAS02], [CAS06], [CHE98], [FON03] y [YAM97].
- *Métodos de segundo orden.* El algoritmo de retropropagación utiliza la información proporcionada por la primera derivada de la función de error. Sin embargo, se ha demostrado que el uso de las derivadas segundas incrementa la velocidad del aprendizaje. Los algoritmos que las usan están entre los más rápidos en términos de convergencia. Algunos de los más utilizados son el algoritmo *BFGS Quasi-Newton* [DEN83], el *Levenberg-Marquardt* [HAG94] y el de *Gradiente Conjugado* [MOL93] y [POW77]. No obstante, estos métodos implican un coste computacional considerable, por lo que no siempre resultan practicable cuando se manejan ANN y/o conjuntos de entrenamiento de gran tamaño [LEC98].
- *Paso de aprendizaje adaptativo.* En el algoritmo de retropropagación la tasa de aprendizaje es constante; sin embargo, variar su valor podría acelerar y mejorar el aprendizaje. Se han desarrollado diversos métodos heurísticos para la adaptación dinámica de la tasa de aprendizaje [HUS88], [JAC88] y [VOG88], así como para la autodeterminación de este parámetro [ALM99], [ORR96], [SCH02] y [WEI91].
- *Inicialización apropiada de los pesos.* El punto de partida del entrenamiento, determinado por los valores iniciales de los pesos, también influye en la calidad de la convergencia hacia el mínimo de la función de error. Por este motivo, se han propuesto diversos esquemas para la correcta inicialización de los pesos.

Uno de los más conocidos es el propuesto por Nguyen y Widrow [NGU90] que asigna a cada neurona oculta una porción del rango de la respuesta deseada.

- *Versiones por lotes y estocástica.* Como se ha visto, el algoritmo de retropropagación del error permite calcular el error y actualizar los pesos, bien sobre todo el conjunto de entrenamiento, bien ejemplo a ejemplo. Esta opción puede acelerar el tiempo de convergencia cuando se manejan conjuntos de entrenamiento de gran tamaño en problemas de clasificación [LEC98].

4.3.6.3 Redes de base radial

La perceptrón multicapa se caracteriza por utilizar neuronas cuya salida es una función (normalmente no lineal) del producto escalar entre el vector de entradas y un vector de pesos. Otro tipo de red neuronal con aprendizaje no supervisado lo constituyen las *Redes de Neuronas con Funciones de Base Radial*. En este tipo de red, el nivel de activación de una neurona oculta estará determinado por la *distancia* entre el vector x de entrada a la red y un vector prototipo asociado a dicha neurona. Una representación esquemática de una Red de Base Radial se presenta en la Fig. 4.6. Más información de este tipo de redes se puede hallar en [PAL08] o [RIC94].

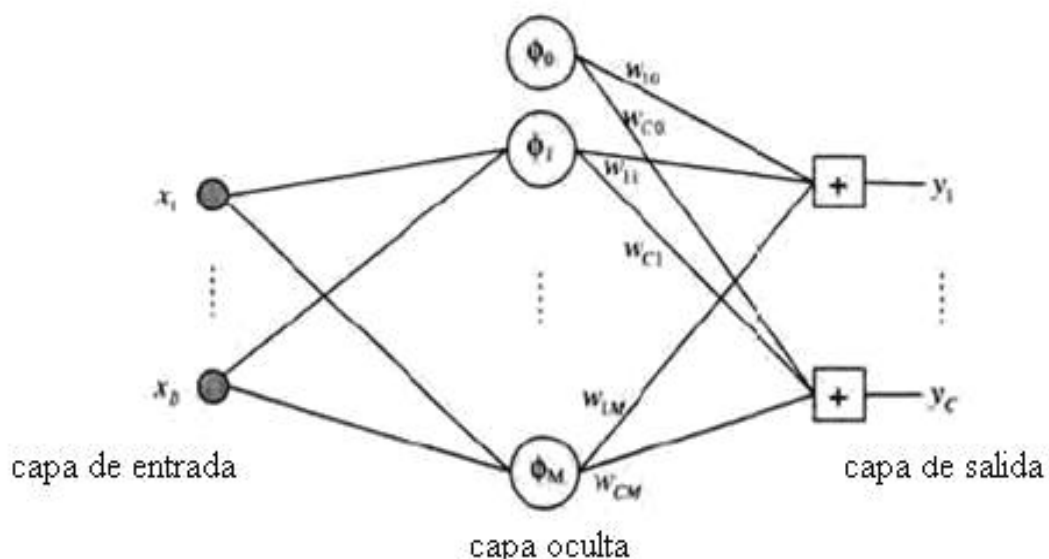


Figura 4.6: Arquitectura de una red de base radial [PAL08].

4.3.7 Generalización

Si se muestran todas las posibles entradas y salidas a una red de propagación hacia atrás, la red probablemente encontrará un conjunto de pesos que haga corresponder las entradas con las salidas, sin embargo, en la práctica no es posible proveer a la red con todas las entradas posibles [RIC94]. De hecho, cuando se trabaja con problemas de clasificación, lo que se espera de la red es que una vez entrenada con cierta cantidad de entrada, ésta sea capaz de clasificar correctamente la mayor cantidad de patrones que no fueron utilizados en el entrenamiento. Esto se basa en la suposición de que patrones similares tendrán características similares que permitirán diferenciarlos unos de otros. Por ejemplo, si se entrena a la red con características de ensayos obtenidos de motores con diferentes estados de fallo, motor sano, con barra rota, etc., se espera que las características de motores con estados de fallo similares sean parecidas entre sí y diferentes a las características de ensayos con otros estados de fallo. Así, si luego se emplea la red con características de ensayos diferentes, se espera que la red pueda clasificar a la mayoría de los ensayos correctamente de acuerdo a su estado de fallo. Esta capacidad de las redes de proporcionar la salida correcta a una entrada aun cuando esta entrada no fue utilizada para el entrenamiento de la misma, se denomina generalización.

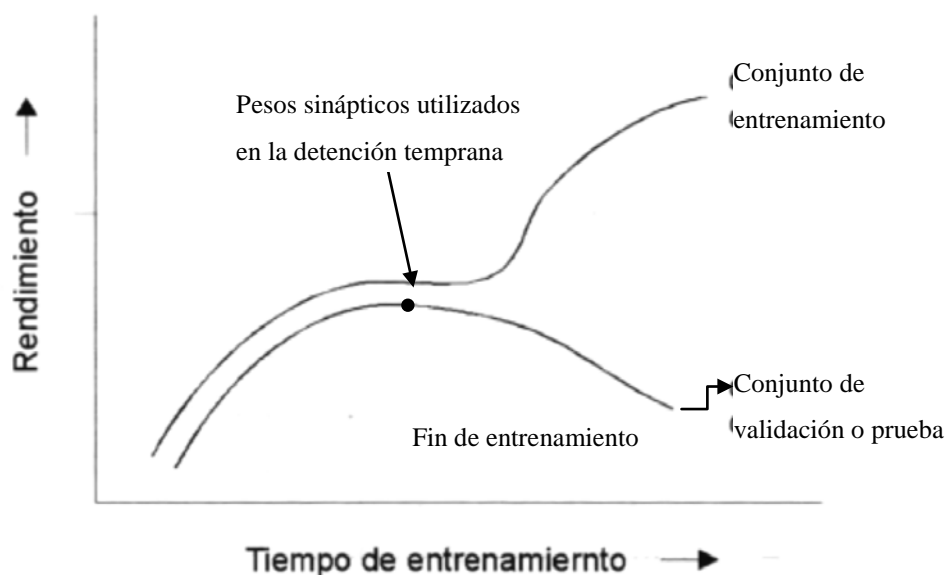


Figura 4.7: Un efecto de generalización común en el aprendizaje con redes neuronales [RIC94].

Sin embargo, hay algunos peligros. La Fig. 4.7 muestra el efecto de generalización durante un largo periodo de entrenamiento. Durante la primera parte del entrenamiento, el rendimiento con el conjunto de entrenamiento mejora conforme la red ajusta sus pesos a lo largo de la propagación hacia atrás. El rendimiento sobre el conjunto de validación (ejemplos con los que no se permite que aprenda la red) también mejora, aunque no tanto como en el ejemplo de entrenamiento. Al poco tiempo, el rendimiento de la red alcanza una meseta conforme los pesos cambian mucho buscando un camino para una mejora posterior. Pero el rendimiento del conjunto de prueba es peor. ¿Por qué? La red comenzó memorizando los pares de entrada-salida concretos en lugar de establecer los pesos que describen de forma general la correspondencia para todos los casos [RIC94], es decir, aprende tanto la relación entre los pares de entrada salida como el ruido o incertidumbre propio de toda medición. Se considera que la red se ha sobreentrenado, es decir, ha particularizado tanto sus pesos sinápticos a las entradas del grupo de entrenamiento que proporciona una salida con errores muy pequeños para las entradas de este grupo a costa de producir errores más importantes con entradas diferentes.

4.3.7.1 Detención temprana

Una forma de evitar el sobreentrenamiento consiste en dividir el grupo de entrenamiento en dos, uno de entrenamiento propiamente dicho y otro grupo de prueba [BIS95]. El grupo de entrenamiento es utilizado para cambiar los pesos sinápticos, mientras que el rendimiento (o el error) de la red con el grupo de prueba es calculado en cada iteración del algoritmo sin intervenir directamente en la actualización de pesos. Los pesos sinápticos de la red son guardados en memoria cada vez que se modifican. Como se describió en la sección anterior, el rendimiento de la red inicialmente mejora para ambos grupos, entrenamiento y prueba, hasta un punto en que el rendimiento en el grupo de prueba comienza a empeorar mientras que el rendimiento de la red con el grupo de entrenamiento sigue subiendo (o su error tiende a cero). En este punto se detiene el proceso de entrenamiento y se utilizan los pesos sinápticos de la iteración que consiguió el mejor desempeño con el grupo de prueba (Fig. 4.7). Hay que resaltar que el grupo de prueba no participa directamente en la modificación de los pesos por lo que el rendimiento de la red con dicha prueba podría empeorar en una iteración y mejorar en la siguiente. Debido a esto, generalmente se elige como criterio de parada del algoritmo un determinado número de iteración sin mejora del rendimiento de la red con el grupo de

prueba. Es decir, el algoritmo de propagación hacia atrás sigue cambiando los pesos sinápticos de la red una cierta cantidad de iteraciones sin mejoras con el grupo de prueba antes de detener el proceso de optimización y seleccionar el conjunto de pesos que mejor rendimiento consiguieron con el grupo de prueba.

4.3.7.2 Equilibrio sesgo varianza (bias variance trade-off dilemmas)

Cuando una red neuronal no se comporta como un predictor perfecto se produce un cierto error. Este error puede ser separado en dos componentes [BIS95]:

- a) Sesgo (bias) es el componente que mide el grado en que, en promedio sobre todos los conjuntos de datos, la salida de la red difiere del resultado esperado.
- b) Varianza: mide el grado en que la salida de la red depende de la elección particular del grupo de datos.

Una red con muchas neuronas en la capa oculta tendrá un sesgo bajo pero una varianza alta, esto es, debido a la gran cantidad de neuronas podrá modificar los pesos para que a cada entrada le corresponda una salida muy cercana a la deseada, pero estas salidas dependerán del grupo de datos que se consideren variando mucho al cambiar los datos de entrenamiento. Por el contrario, una red muy simple, con pocas neuronas, tendrá un rendimiento similar independientemente del grupo de datos, pero posiblemente este rendimiento no será muy bueno, es decir, tendrá un sesgo alto pero una varianza baja. Considerando esto, se pretende que los parámetros de las redes se calibren para que haya un equilibrio en el sesgo y la varianza, a fin de conseguir una buena generalización. El problema de encontrar el equilibrio entre sesgo y varianza se conoce como Dilema Sesgo Varianza (*Bias Variance Dilemma*).

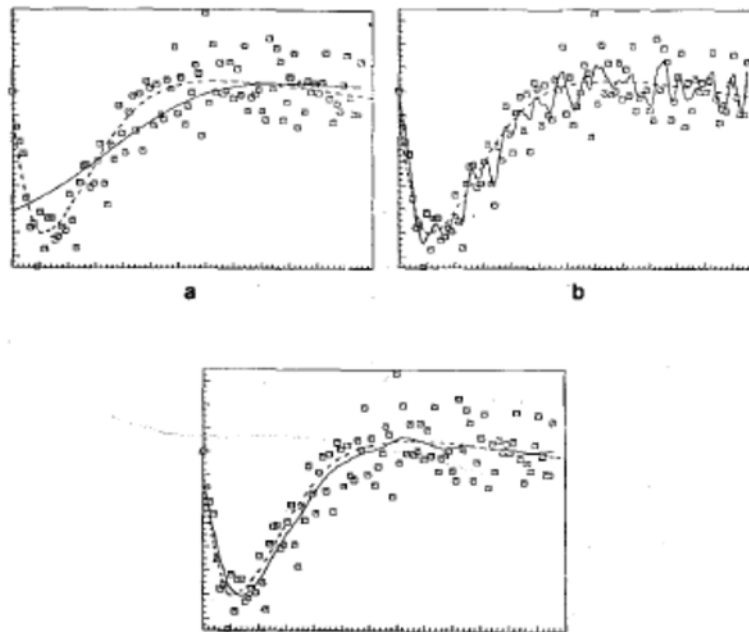


Figura 4.8: Ejemplo de una aproximación con alto sesgo y baja varianza (a), alta varianza y bajo sesgo (b) un equilibrio entre sesgo y varianza [WAH75].

La Fig. 4.8 explica los conceptos de sesgo y varianza con un ejemplo sencillo [WAH75]. Un centenar de observaciones (cuadrados) generadas de acuerdo con la ecuación $y=g(x) + \eta$, donde η es “ruido” con distribución independiente de x y $g(x) = 4,26(e^{-x} - 4e^{-2x} + 3e^{-3x})$. El ruido es gaussiano de media cero con desviación estándar de 0,2. En cada panel, la curva discontinua es g y la curva de trazo continuo es un ajuste spline. (a) Con los parámetros elegidos para controlar la varianza. (b) con parámetros elegidos para controlar el sesgo. (c) con parámetros con valores para equilibrar el sesgo y la varianza [WAH75].

Una explicación más detallada del Dilema Sesgo Varianza se puede encontrar en [STU92] y [BRI11].

4.3.8 Ensamble de redes neuronales

Es una práctica común en la aplicación de redes neuronales entrenar muchas redes diferentes y después seleccionar la mejor, sobre la base del rendimiento en un grupo de validación independiente, y mantener sólo esta red y desechar el resto. Hay dos desventajas con este tipo de enfoque. En primer lugar, todo el esfuerzo involucrado en la formación de las redes restantes se desperdicia. En segundo lugar, la generalización de rendimiento en el conjunto de validación tiene un componente aleatorio debido al ruido en los datos, por lo que la red que tenía el mejor rendimiento en el conjunto de

validación puede no ser la que tenga el mejor rendimiento en nuevos datos de ensayo [BIS95].

Estos inconvenientes se pueden superar mediante la combinación de las redes entre sí para formar un comité o ensamble [HAN90], [FER09]. La importancia de este enfoque es que puede dar lugar a mejoras significativas en las predicciones sobre los nuevos datos, mientras que requiere de poco esfuerzo computacional adicional. De hecho, el rendimiento de un ensamble puede ser mejor que el rendimiento de la mejor red simple utilizada en forma aislada [BIS95].

Existen distintas formas en que los resultados de las redes neuronales aisladas se combinan para determinar el resultado del ensamble. Tres de las más usadas son [FER09]:

- Majority Voting: Donde cada patrón es asignado a la clase más votada por sus clasificadores integrantes. Siendo $C(x, g_j)$ la clase a que el clasificador g_j asigna al patrón x la asignación efectuada por el ensamble, $C(x)$ vendrá dada por la moda de las asignaciones individuales:

$$C(x) = Mo\{C(x, g_j)\} \quad (4.32)$$

- Simple promediado: Se calcula la media aritmética, para cada patrón, de las probabilidades de asignación a cada una de las clases para cada una de las T redes. La asignación se hará a aquella clase para la que resulte una mayor probabilidad media. Siendo $P(x, g_j, C_k)$ la probabilidad estimada por el clasificador g_j de pertenencia a la clase C_k del patrón x , la clase asignada será:

$$C(x) = \arg \max_k \sum_{j=1}^T P(x, g_j, C_k) \quad (4.33)$$

expresión en la que se ha prescindido, por ser constante para todos los elementos, de la división por el número total de elementos promediados,

- Winner-Takes-All: Se asigna cada patrón a la clase a la que lo asigna el clasificador que presenta la mayor probabilidad de asignación:

$$C(x) = \arg_k \max_{j,k} \{P(x, g_j, C_k)\} \quad (4.34)$$

Podemos mostrar fácilmente que el proceso de ensamble por simple promediado no puede producir un aumento en el error esperado, obteniéndose generalmente una reducción útil en el error [BIS95].

La reducción en el error puede ser vista como derivada de una reducción en la varianza debido al promediado sobre muchas soluciones. Esto sugiere que los miembros del ensamble no deben ser elegidos individualmente para tener un equilibrio óptimo entre el sesgo y la varianza, pero deben tener un sesgo relativamente menor, ya que la variación adicional se puede quitar haciendo un promedio [BIS95].

Un ensamble o comité de clasificadores puede estar compuesto de diferentes tipos de algoritmos, es decir, se podrían emplear redes neuronales con otros algoritmos de inteligencia artificial como máquinas de vectores de soporte, (SVM), o con métodos estadísticos como la regresión logística o el análisis discriminante. La Fig. 4.9 muestra un esquema de un ensamble de clasificadores diferentes [CLA11]. En este ensamble las entradas son suministradas a varios algoritmos o “Expertos” diferentes y las salidas de los Expertos son sumadas mediante una ponderación calculada por una red especializada, la “Gating network”. Se asume que cada Experto es mejor al clasificar cierto tipo de entradas, es decir, cada algoritmo se especializa en cierta zona del espacio de búsqueda. La Gating network es la encargada de aprender para qué zonas del espacio de búsqueda es mejor cada Experto y al recibir una entrada nueva estima qué Experto tiene más probabilidad de clasificar correctamente a la nueva entrada. Así, las salidas no son promediadas directamente, sino que la Gating network calcula una ponderación para dar más peso a la salida del Experto que probablemente haya realizado la mejor clasificación.

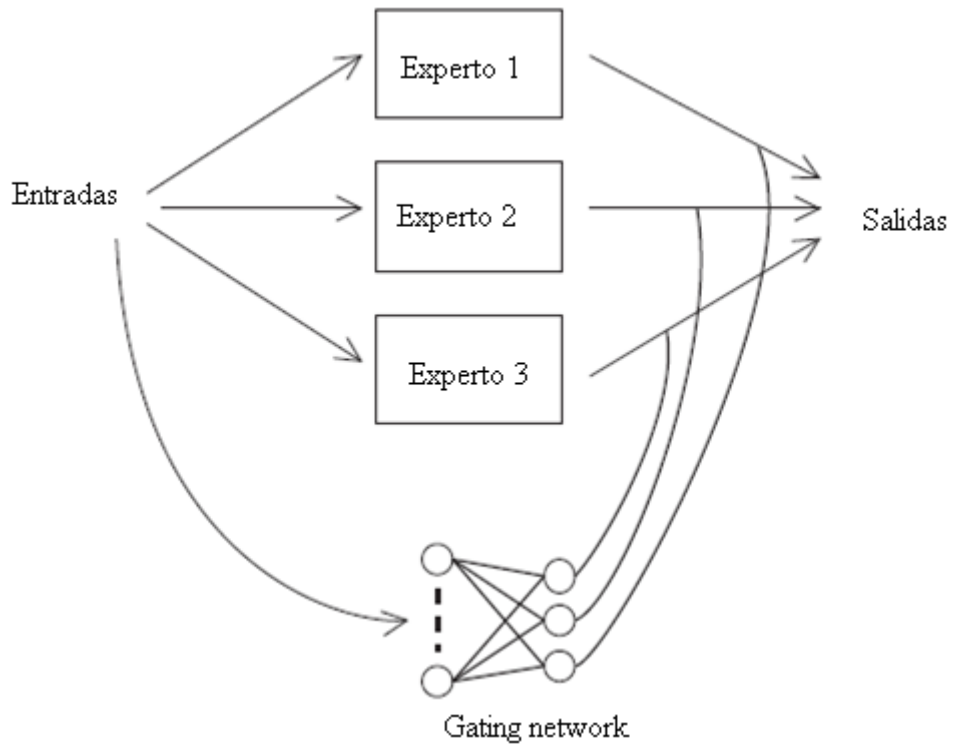


Figura 4.9: Esquema general de ensamblaje de diferentes clasificadores, donde la “Gating network” es la encargada de estimar la ponderación a ser aplicada a la salida de cada clasificador [CLA11].

5 Influencia de los convertidores de frecuencia en el diagnóstico de motores de inducción

5.1. Introducción

El objetivo principal del presente capítulo es presentar los aspectos básicos de funcionamiento de un convertidor electrónico de potencia, sin realizar una descripción exhaustiva de los mismos. También se comparará la alimentación con convertidor de potencia con una alimentación de red, senoidal pura idealmente. En esta descripción se pondrá énfasis en los aspectos más relevantes para el diagnóstico de fallos en motores de inducción.

El motor de inducción trifásico presenta una gran ventaja con respecto a otro tipo de motores. Se puede conectar directamente a la red trifásica, sin necesidad de otros sistemas para adaptar la fuente de alimentación, como requieren los motores de corriente continua. Además, a diferencia de los motores síncronos, puede arrancar directamente en una conexión directa a red. Si no se necesita regulación de velocidad, el sistema de conexión es muy simple. El inconveniente es que no se puede fijar la velocidad de giro del motor, que vendrá determinada por los siguientes factores:

- Frecuencia de la red.
- Número de polos de la máquina.
- Par resistente de la máquina accionada.

La frecuencia de la red y el número de polos de la máquina fijan la velocidad de sincronismo del motor. El motor asíncrono siempre girará por debajo de esa velocidad, pero próximo a ella. Un motor de 1 par de polos en una red de 50 Hz tendrá una velocidad de sincronismo de 3000 rpm; si tiene dos pares de polos, 1500 rpm, y así sucesivamente. Las velocidades de sincronismo posibles en una red de 50 Hz serían: 3000, 1500, 1000, 750, rpm. Entonces, hay que escoger el motor con un número de polos que proporcione una velocidad de sincronismo por encima de la velocidad esperada del accionamiento y lo más próxima a ella. La velocidad de giro real dependerá del par resistente. Cuanto mayor sea el par resistente, más se alejará la velocidad real del motor de la velocidad de sincronismo. Esto se mide mediante el deslizamiento, que puede llegar a tomar valores cercanos al 10%, según el tipo de motor

Capítulo 5: Influencia de los convertidores de frecuencia en el diagnóstico de Motores de Inducción

y las características de la carga accionada. Se puede deducir que, si la carga accionada presenta una variación del par resistente, la velocidad de giro no será fija. Solo se obtiene una velocidad fija si el par resistente no cambia con el tiempo y se mantiene constante.

En caso de que la regulación de velocidad sea una necesidad, este sistema de alimentación directa de la red ya no resulta útil. Existen algunos procedimientos de regulación de velocidad, pero ya obsoletos. El más extendido actualmente es la alimentación del motor con un convertidor electrónico de potencia. Desde el punto de vista de la energía, el convertidor de potencia transforma energía eléctrica de entrada, de frecuencia y amplitud constantes, en energía eléctrica de salida con una frecuencia y amplitud variables. La regulación de velocidad se realiza a través de la frecuencia de la tensión de salida del variador o convertidor. Cambiando la frecuencia fundamental, se cambia la velocidad de sincronismo y por tanto, la velocidad de giro del todo el accionamiento. Además de este elemento, para poder realizar la regulación, se debe contar con un algoritmo de control que genere las órdenes de mando del convertidor en función de unas variables o señales de entrada y de la consigna correspondiente, que suele ser la velocidad requerida. Entre los procedimientos de control más comunes se pueden citar los siguientes [RAZ11]:

- Control escalar V/f .
- Control vectorial V/f .
- Control directo del par.
- Direct self-control approach.
- Control vectorial (Flux orientation control).

Todas estas estrategias de control requieren el uso de sensores, reguladores, microprocesadores, etc ... Las más extendidas en la industria son las dos primeras basadas en mantener constante el ratio V/f , que es directamente proporcional al flujo de la máquina.

En los accionamientos modernos, el motor de inducción suele ir alimentado por un convertidor electrónico de potencia. Aunque esto supone una mayor inversión inicial, hay razones técnicas y económicas que obligan a su uso [RAZ11] [GRO00]:

Capítulo 5: Influencia de los convertidores de frecuencia en el diagnóstico de Motores de Inducción

- Rendimiento energético superior. Se ajusta el par y velocidad del motor a lo que realmente demanda la carga.
- Control más preciso en aplicaciones donde es esencial poder fijar una velocidad de giro concreta.
- Disminución y control de la corriente de arranque.

Desde un punto de vista del mantenimiento, la instalación de un convertidor supone aumentar el riesgo de fallo del accionamiento. Además de los posibles fallos del motor, ahora hay que añadir el riesgo de fallo del convertidor y de los sensores que sean necesarios para su correcto funcionamiento. Pero esto no es objeto de este trabajo. Lo que importa aquí es si la presencia de un convertidor supone una dificultad o una mejora a la hora de poder detectar o diagnosticar un fallo del motor de inducción.

5.2. Funcionamiento de un convertidor de tensión.

5.2.1. Introducción.

Los convertidores comerciales suelen contar con varias etapas:

- En una primera etapa se rectifica la tensión alterna de 50 Hz de la red. El rectificador suele ser un puente diodos no controlado.
- En una segunda etapa, en el denominado bus de continua, se filtra la tensión proporcionada por el rectificador, que no está exenta de un cierto rizado.
- En la tercera etapa, esta tensión continua se convierte en tensión alterna de la frecuencia deseada. Esta etapa del convertidor es totalmente controlada y se construye con transistores bipolares de puerta aislada, IGBTs, que se caracterizan por soportar mayores gradientes de tensión, cortar corrientes más elevadas y por tener menores tiempos de conmutación que otros tipos de dispositivos electrónicos de potencia.

Como el motor representa una carga inductiva para el convertidor, la conmutación de los IGBT se hará, generalmente, cuando la corriente no sea nula. Es decir, habrá conmutación forzada. Los IGBTs suelen llevar un diodo de libre circulación en paralelo. La tercera etapa del convertidor puede tener diferentes estructuras pero nos centraremos

en los convertidores de dos niveles, que suelen ser los comerciales, para medias y bajas potencias, que es nuestro caso.

5.2.2. Inversor de tensión de dos niveles.

Existen diversas técnicas para generar una tensión de amplitud y frecuencia variables a partir de una tensión continua. Nosotros nos vamos a centrar en la técnica conocida como *modulación del ancho de pulso* en convertidores de dos niveles. Esta es la técnica más empleada a nivel comercial [RAZ11] y la que emplean los convertidores que se han utilizado en este estudio.




Figura 5.1. Esquema simplificado de un convertidor de dos niveles [WU06].

En la Fig. 5.1 se muestra el esquema simplificado y sencillo de un convertidor de tensión de dos niveles (sin la etapa previa de rectificación) [WU06]. La sección de salida, donde se conecta la carga trifásica, en este caso el motor de inducción, consta de tres ramas, con dos IGBTs por rama con un diodo de libre circulación en paralelo. Los IGBT pueden sustituirse por otros elementos, que en inglés se denominan *active switches*. Dependiendo del nivel de la tensión de continua, se pueden colocar varios de estos elementos en serie (como en la Fig. 5.1). Cada fase de la carga trifásica se conecta al punto intermedio de cada una de estas ramas.

Los IGBTs pueden considerarse como interruptores con telemando. Es decir, tienen una entrada que les indica cuando deben abrirse y cortar la corriente y cuando deben cerrarse y dejarla pasar. Hay diferentes formas de generar coordinadamente las señales de mando de los IGBT para crear, en este caso, un sistema de tensiones trifásico,

Capítulo 5: Influencia de los convertidores de frecuencia en el diagnóstico de Motores de Inducción

equilibrado y de la frecuencia deseada. La técnica más empleada y universalmente aceptada es la denominada PWM senoidal. PWM corresponde a las siglas en inglés para modulación del ancho de pulso. Esta técnica emplea dos ondas para generar las señales de mando de los IGBTs. Estas señales de mando tienen forma de pulsos y se generan comparando una onda portadora (*carrier wave*), normalmente con forma triangular, con una onda moduladora (*modulating wave*), normalmente con forma senoidal. En el caso de alimentar una carga trifásica se generan tres ondas moduladoras, una por cada fase, desfasadas entre sí 120°. Para controlar la generación de la tensión deseada se definen dos parámetros [WU06]:

- Índice de modulación de amplitud. Se suele representar por el término m_a y se define como:

$$m_a = \frac{v_m}{v_{cr}} \quad (5.1)$$

- Índice de modulación de frecuencia. Se representa por el término m_f y se define como sigue:

$$m_f = \frac{f_{cr}}{f_m} \quad (5.2)$$

donde:

- V_m corresponde al valor de pico de la onda moduladora, con forma de tensión senoidal
- V_{cr} corresponde al valor de pico de la onda portadora, con forma de tensión triangular
- f_m es la frecuencia de la onda moduladora
- f_{cr} es la frecuencia de la onda portadora

En [HOL03] se propone otra definición y nomenclatura para el índice de modulación, aunque es totalmente equivalente a la propuesta en [WU06]:

$$M = \frac{V_0}{V_{dc}} \quad (5.3)$$

donde V_0 es el valor de pico de la tensión de salida.

La componente fundamental de la tensión de salida del convertidor se controla a través del índice de modulación de amplitud. Normalmente se regula el valor de la amplitud de la onda moduladora, manteniendo constante el valor de pico de la onda portadora. La

frecuencia de la componente fundamental se controla a través del índice de modulación de frecuencia.




Figura 5.2. Formas de onda de un esquema PWM senoidal [WU06].

En la Fig. 5.2 se muestran las ondas involucradas en la generación de los pulsos de conmutación de los IGBTs de un inversor de tensión de dos niveles. En la parte superior se muestran las tres ondas moduladoras senoidales, una por cada fase. Sus valores de pico son V_{mA} , V_{mB} y V_{mC} respectivamente. Se observa cómo las tres ondas moduladoras están desfasadas entre sí 120° . La onda portadora es de tipo triangular y su valor de pico es V_{cr} . La señal de mando de los IGBTs se determina comparando la onda portadora con las ondas moduladoras. Para explicarlo mejor, vamos a ilustrarlo con un ejemplo. Consideramos los IGBTs S_1 y S_4 de la rama A de la Fig. 5.2. Cuando la tensión de la onda moduladora de la fase A es superior o igual a la tensión de la onda portadora triangular ($V_A \geq V_{cr}$), el IGBT superior de la rama A, S_1 , se cierra (estado ON) dejando pasar la corriente que demanda la carga. El IGBT inferior de la misma rama, S_4 , funciona de forma complementaria. Es decir, cuando el superior está en ON, el inferior está en OFF y al contrario.

En [HOL03] se realiza una explicación similar, pero en este caso divide la tensión del bus de continua en dos valores ($\pm V_{dc}$) conectando a tierra el punto central del bus (Fig.

5.3). Las tensiones generadas entre los tres terminales de fase (A, B y C) y el terminal z del bus de continua son iguales que las mostradas en la Fig. 5.2. También son de dos niveles, pero ahora las dos tensiones son $+V_{dc}$ y $-V_{dc}$. Obsérvese la Fig. 5.4, donde se muestran las tres tensiones de línea desplazadas entre sí 120° .

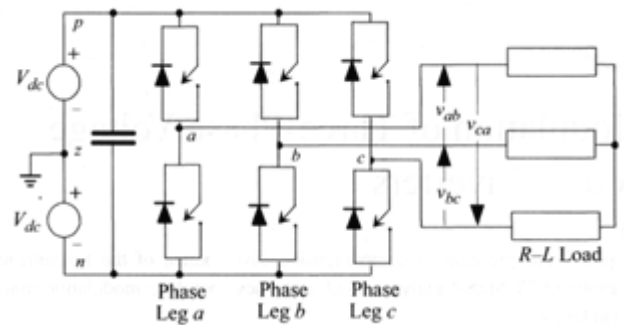


Figura 5.3. Esquema simplificado de un convertidor de dos niveles con divisor de tensión en el bus de continua [HOL03].

En la segunda gráfica por la parte superior de la Fig. 5.2 se muestra la tensión generada entre el terminal A y el terminal N que se ha obtenido comparando las onda moduladora A y la onda portadora. Fijarse (ver Fig. 5.1) que el terminal N no es el neutro de la carga O, si no el terminal negativo del bus de continua del convertidor. Como se puede observar fácilmente, cuando la onda moduladora es superior o igual a la portadora (S_1 en ON y S_4 en OFF), la tensión V_{AN} toma el valor de la tensión V_d en el bus de continua. Cuando es inferior (S_1 en OFF y S_4 en ON), esta tensión es cero. La tensión V_{AN} sólo puede tomar dos valores, V_d y 0, y por esta razón este tipo de convertidor se denomina de dos niveles. En la operación del inversor se pueden producir cortocircuitos si no se toman las medidas adecuadas. Durante los transitorios podrían estar en ON los dos IGBTs de una rama y producirse el corto. Para evitarlo, se introduce un tiempo de retardo, antes de que un IGBT pase a ON, durante el cual los dos IGBTs están en OFF.

La tensión de línea con la que se alimenta la carga se obtendrá de la siguiente forma:

$$V_{AB} = V_{AN} - V_{BN} \quad (5.4)$$

En la Fig. 5 4 se muestra la forma de onda resultante que también tiene forma de tren de pulsos de anchura variable, pero ahora con tres niveles de tensión: V_d , 0 y $-V_d$. Este tren de pulsos es una onda periódica cuya componente fundamental también se ha dibujado superpuesta en la misma figura. Por supuesto, la componente fundamental es senoidal y

Capítulo 5: Influencia de los convertidores de frecuencia en el diagnóstico de Motores de Inducción

su amplitud y frecuencia se regulan de forma independiente a través de los índices de modulación de amplitud y frecuencia, respectivamente.

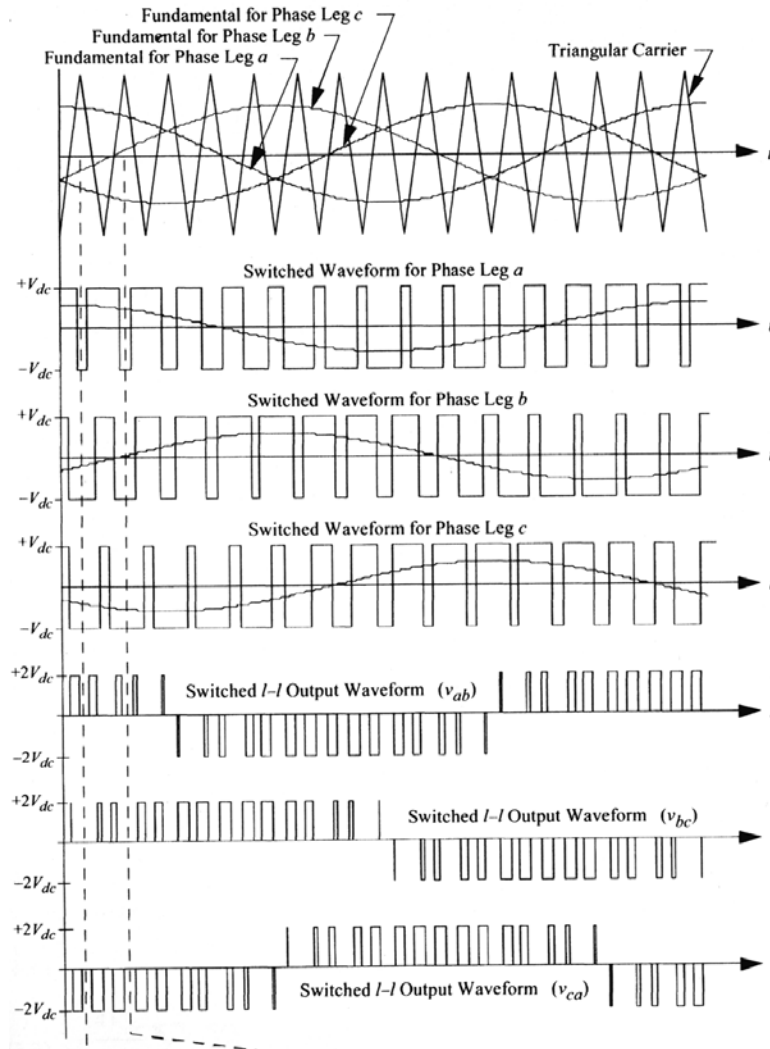


Figura 5.4. Tensiones de línea generadas según un esquema PWM senoidal para el convertidor de la Fig. 5.3 [HOL03].

La frecuencia de conmutación de los IGBTs coincide en este caso con la frecuencia de la onda portadora y se puede calcular de la siguiente forma:

$$f_{sw} = f_{cr} = m_f \cdot f_m \quad (5.5)$$

La frecuencia de la onda moduladora es la frecuencia buscada en la componente principal de la tensión de línea. En la Fig. 5.2, la tensión V_{AN} presenta 9 pulsos por ciclo de la frecuencia de la componente fundamental de V_{AB} , que son 60 Hz. Por lo tanto, la frecuencia de conmutación será $f_{sw} = 9 \cdot 60 = 540$ Hz. Esta es también la frecuencia de la onda portadora. Esto sólo ocurre en los convertidores de dos niveles.

Si la onda portadora está sincronizada con la onda moduladora (es decir, el índice de modulación de frecuencia m_f es un número entero), el esquema de modulación se conoce como PWM síncrono. El esquema de modulación también puede ser asíncrono. En ese caso, la frecuencia de la onda portadora, f_{cr} , suele ser fija y sólo se cambia el valor del índice de modulación de frecuencia, m_f , que puede ser un número no entero. El esquema PWM asíncrono es más fácil de implementar con circuitos analógicos y el PWM síncrono es más sencillo de implementar en procesadores digitales de señales (DSP). En el primer esquema además surgen en el espectro de frecuencias armónicos que no son múltiplos enteros de la frecuencia fundamental. Los convertidores que se analizan en este trabajo emplean un esquema PWM síncrono. La frecuencia de conmutación se puede fijar a voluntad, pero se ha mantenido el valor de fábrica que en todos los modelos es 4 kHz.

5.3. Contenido armónico de la tensión de salida.

Fijándonos en la Fig. 5.4, la componente fundamental de las tres tensiones entre los terminales a , b y c y el punto medio z del bus de continua (Fig. 5 3) son las siguientes [HOL03]:

$$V_{az,1} = V_0 \cos(\varpi_0 t) = M V_{dc} \cos(\varpi_0 t) \quad (5.6)$$

$$V_{bz,1} = V_0 \cos(\varpi_0 t - 2\pi/3) = M V_{dc} \cos(\varpi_0 t - 2\pi/3) \quad (5.7)$$

$$V_{cz,1} = V_0 \cos(\varpi_0 t + 2\pi/3) = M V_{dc} \cos(\varpi_0 t + 2\pi/3) \quad (5.8)$$

La componente fundamental de las tensiones de línea de salida se obtienen restando, dos a dos, las tensiones anteriores [HOL03]:

$$V_{ab,1} = V_{az,1} - V_{bz,1} = M \sqrt{3} V_{dc} \cos(\varpi_0 t + \pi/6) \quad (5.9)$$

$$V_{bc,1} = V_{bz,1} - V_{cz,1} = M \sqrt{3} V_{dc} \cos(\varpi_0 t - \pi/2) \quad (5.10)$$

$$V_{ca,1} = V_{cz,1} - V_{az,1} = M \sqrt{3} V_{dc} \cos(\varpi_0 t + 5\pi/6) \quad (5.11)$$

El índice de modulación M máximo puede ser 1, y en este caso, el valor de pico máximo que se puede obtener en la tensión de línea de salida es $\sqrt{3}V_{dc}$.

En [HOL03] se puede ver el procedimiento para obtener la solución armónica de las tensiones entre los terminales a , b y c respecto al punto medio z del bus de continua.

Capítulo 5: Influencia de los convertidores de frecuencia en el diagnóstico de Motores
de Inducción

$$V_{az}(t) = V_{dc} + V_{dc}M \cos(\varpi_0 t) + \frac{4V_{dc}}{\pi} \sum_{m=1}^{\infty} \sum_{n=-\infty}^{\infty} \frac{1}{m} J_n\left(m \frac{\pi}{2} M\right) \text{sen}\left([m+n] \frac{\pi}{2}\right) \cos(m\varpi_{cr}t + n\varpi_0 t) \quad (5.12)$$

$$V_{bz}(t) = V_{dc} + V_{dc}M \cos\left(\varpi_0 t - \frac{2\pi}{3}\right) + \frac{4V_{dc}}{\pi} \sum_{m=1}^{\infty} \sum_{n=-\infty}^{\infty} \frac{1}{m} J_n\left(m \frac{\pi}{2} M\right) \text{sen}\left([m+n] \frac{\pi}{2}\right) \cos\left(m\varpi_{cr}t + n\left[\varpi_0 t - \frac{2\pi}{3}\right]\right) \quad (5.13)$$

$$V_{cz}(t) = V_{dc} + V_{dc}M \cos\left(\varpi_0 t + \frac{2\pi}{3}\right) + \frac{4V_{dc}}{\pi} \sum_{m=1}^{\infty} \sum_{n=-\infty}^{\infty} \frac{1}{m} J_n\left(m \frac{\pi}{2} M\right) \text{sen}\left([m+n] \frac{\pi}{2}\right) \cos\left(m\varpi_{cr}t + n\left[\varpi_0 t + \frac{2\pi}{3}\right]\right) \quad (5.14)$$

donde:

- J_n es la función de Bessel de orden n .
- ω_{cr} es la frecuencia angular de la onda portadora.

La tensión de línea entre los terminales a y b es la siguiente [HOL03]:

$$V_{ab}(t) = V_{az}(t) - V_{bz}(t) = \sqrt{3} V_{dc}M \cos\left(\varpi_0 t + \frac{\pi}{6}\right) + \frac{8V_{dc}}{\pi} \sum_{m=1}^{\infty} \sum_{n=-\infty}^{\infty} \frac{1}{m} J_n\left(m \frac{\pi}{2} M\right) \text{sen}\left([m+n] \frac{\pi}{2}\right) \text{sen}\left(n \frac{\pi}{3}\right) \cos\left(m\varpi_{cr}t + n\left[\varpi_0 t - \frac{\pi}{3}\right] + \frac{\pi}{2}\right) \quad (5.15)$$

Al analizar esta última ecuación, llama la atención primero la presencia del armónico principal a la frecuencia deseada ω_0 . El resto del contenido armónico viene establecido por el doble sumatorio. Hay que distinguir los factores de determinan la amplitud del armónico que son la función de Bessel y los dos senos que no dependen del tiempo. Por ejemplo, se cancelan todos los armónicos triples debido al factor $\text{sen}(n\pi/3)$. También se cancelan todos los armónicos pares en los que la combinación $(m+n)$ es múltiplo de 2. Las frecuencias de los armónicos presentes serán múltiplos de la frecuencia de la onda portadora ω_{cr} ($m \geq 1$). Obsérvese que n va desde $-\infty$ a $+\infty$, pasando por cero. Es decir, adopta los valores positivos y negativos del mismo número entero. Quizás, la siguiente notación sea más habitual:

$$V_{ab}(t) = V_{az}(t) - V_{bz}(t) = \sqrt{3} V_{dc}M \cos\left(\varpi_0 t + \frac{\pi}{6}\right) + \frac{8V_{dc}}{\pi} \sum_{m=1}^{\infty} \sum_{n=-\infty}^{\infty} \frac{1}{m} J_n\left(m \frac{\pi}{2} M\right) \text{sen}\left([m+n] \frac{\pi}{2}\right) \text{sen}\left(n \frac{\pi}{3}\right) \quad (5.16)$$

Capítulo 5: Influencia de los convertidores de frecuencia en el diagnóstico de Motores de Inducción

$$\cos(m\omega_{cr}t \pm n \left[\omega_0 t - \frac{\pi}{3} \right] + \frac{\pi}{2})$$

Para $m=1$, aparecen alrededor de la frecuencia de la onda portadora sólo las bandas pares: $\omega_{cr} \pm 2\omega_0$, $\omega_{cr} \pm 4\omega_0$, ... Para $m=2$, segundo grupo de frecuencias relacionada con la onda portadora, el contenido armónico es mucho más rico. Aparece, al menos teóricamente, las siguientes bandas: $2\omega_{cr} \pm \omega_0$, $2\omega_{cr} \pm 5\omega_0$, $2\omega_{cr} \pm 7\omega_0$, ...

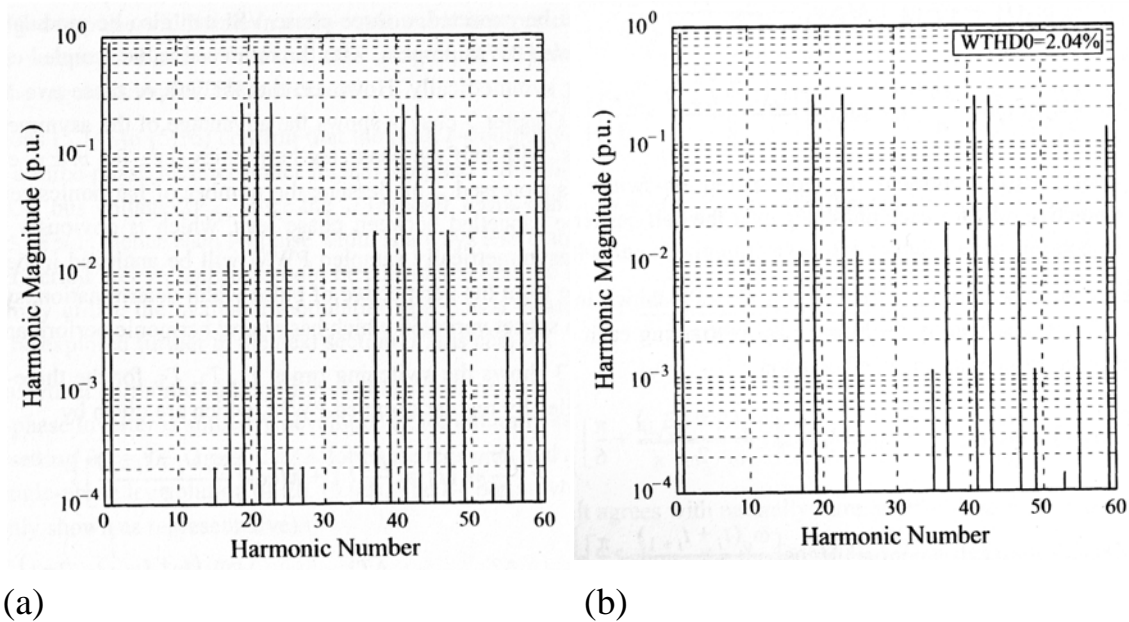


Figura 5.5. Contenido armónico teórico (PSD normalizado respecto a $2V_{dc}$) en convertidor de dos niveles con un esquema PWM senoidal: (a) Tensión V_{az} , (b) Tensión V_{ab} . El índice de modulación M es 0,9 y el índice de modulación de frecuencia es 21 [HOL03].

En la Fig. 5 5 se muestra el contenido armónico teórico de la tensión de línea y la tensión de una rama respecto al punto z. Se puede observar cómo se cancelan en la tensión de línea bastante contenido armónico que sí que aparece en la tensión de la rama respecto al punto z. Este contenido armónico puede variar dependiendo de diferentes estrategias que existen para generar el tren de pulsos. En [HOL03] se comentan las 4 estrategias y se presenta, sin mayor explicación, el diferente contenido armónico para cada una de ellas (ver Fig. 5 6). Obsérvese que algunas de estas estrategias (ver Fig. 5 6 (c) y (d)) generan también armónicos próximos al armónico fundamental.

En [WU06] también se analiza el contenido armónico de la tensión de salida del convertidor, pero de forma menos desarrollada. En la Fig. 5.7 se muestran los resultados teóricos para las siguientes condiciones:

- Índice de modulación de amplitud: 0,8.

Capítulo 5: Influencia de los convertidores de frecuencia en el diagnóstico de Motores de Inducción

- Índice de modulación de frecuencia: 15.
- Frecuencia fundamental: 60 Hz.
- Frecuencia de conmutación: 900 Hz.
- Carga trifásica inductiva con factor de potencia: 0,9.

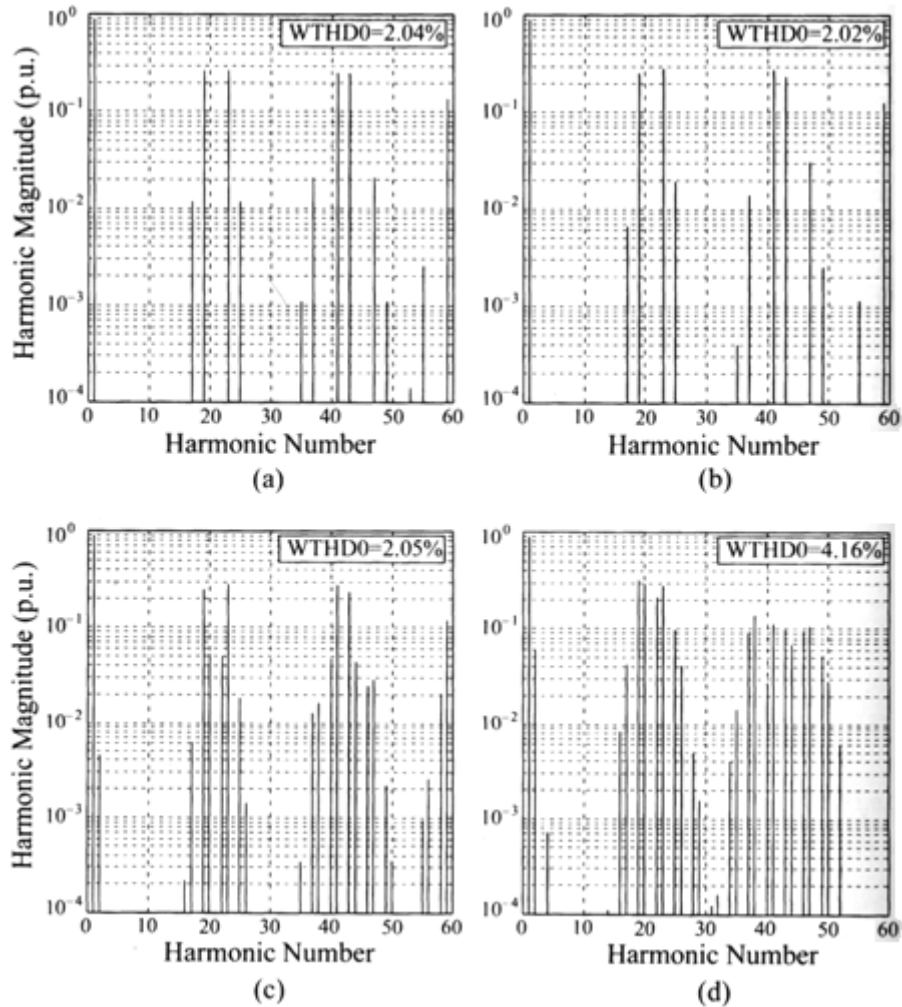


Figura 5.6. Contenido armónico teórico (PSD normalizado respecto a $2V_{dc}$) de la tensión de línea en convertidor de dos niveles con un esquema PWM senoidal. El índice de modulación M es 0,9 y el índice de modulación de frecuencia es 21. (a) Double-edge naturally sampled PWM, (b) Asymmetrical regular sampled PWM, (c) Symmetrical regular sampled PWM, (d) Trailing single-edge regular sampled PWM [HOL03].

En la Fig. 5.8 se muestra el contenido armónico de la tensión de línea en función de diversos parámetros.

Capítulo 5: Influencia de los convertidores de frecuencia en el diagnóstico de Motores de Inducción

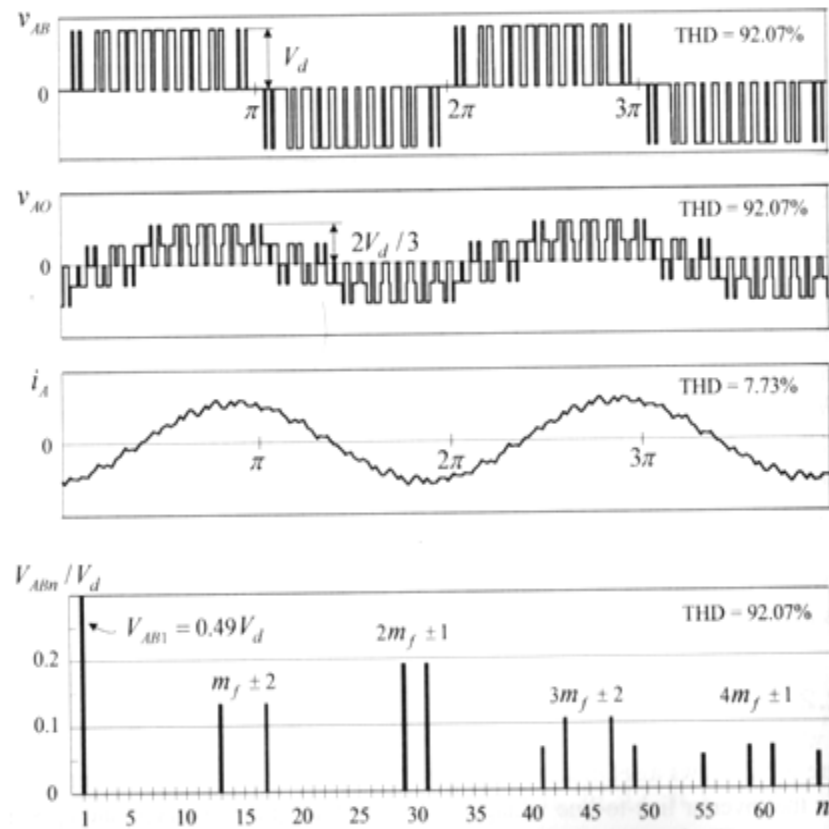


Figura 5.7. Tensión de línea y fase-neutro (neutro real de la carga) para una carga inductiva con factor de potencia 0,9 y con las siguientes condiciones: $m_a = 0,8$, $m_f = 15$, $f_0 = 60$ Hz [WU06].




Figura 5.8. Contenido armónico de la tensión de línea para las condiciones de la Fig. 5 7 [WU06].

5.4. Sobremodulación.

Se produce una sobremodulación cuando el índice de modulación de amplitud (en cualquiera de las dos definiciones expuestas) es superior a la unidad. La sobremodulación produce una reducción del número de pulsos por periodo en la tensión de línea de salida del convertidor. Esto provoca la aparición de armónicos de orden inferior, como pueden ser el 5º y el número 11. Sin embargo, se incrementa el valor de pico de la componente fundamental de la tensión de línea. Por ejemplo, si $m_a = 2$ ($V_{AB1} = 0,744 V_d$), el valor de pico de esta tensión se incrementa un 22% con respecto a $m_a = 1$ ($V_{AB1} = 0,612 V_d$). El valor límite de sobremodulación se obtiene cuando m_a vale 3,24. En este caso, la onda de tensión de línea es cuadrada y el valor de pico de la componente fundamental vale $0,78 V_d$, que es el máximo valor que se puede obtener a partir de un convertidor de dos niveles. La sobremodulación no se suele emplear debido a la dificultad para filtrar los armónicos de baja frecuencia y por la relación entre la amplitud del armónico fundamental y el índice de modulación de amplitud deja de ser lineal. En la Fig. 5 9 se puede observar un ejemplo de sobremodulación.




Figura 5.9. Sobremodulación: $m_a = 2$, $m_f = 15$, $f_0 = 60$ Hz [WU06].

5.2.5. Inyección del tercer armónico en la onda moduladora.

El efecto útil de la sobremodulación es el incremento del valor de pico de la componente fundamental de la tensión de línea. Sin embargo, sus efectos negativos pueden llegar a ser importantes [HOL03]. Una alternativa a la sobremodulación consiste en añadir un tercer armónico. La técnica consiste en modificar la onda moduladora (V_{mA}) añadiendo a la componente fundamental (V_{m1}) otra onda con frecuencia triple (V_{m3}) y amplitud inferior, como se muestra en la Fig. 5.10. De esta forma, se consigue de alguna forma, “aplanar” la onda moduladora en la parte central del semiciclo. Se consigue, como se observa en la Fig. 5.10, que la amplitud de la componente fundamental pueda ser superior a la amplitud de la onda portadora, lo que permite, como en la sobremodulación, incrementar el valor de pico de la componente fundamental de la tensión de línea de salida. Esto se puede realizar manteniendo el valor máximo de la tensión moduladora (\hat{V}_{mA}) inferior al valor máximo de la onda portadora (\hat{V}_{cr}) y evitar los problemas asociados a la sobremodulación. Con esta técnica se puede incrementar el valor de pico de la tensión de línea en un 15% [WU06]. El tercer armónico aparecerá en la tensión de rama con respecto al punto n o punto z del bus de continua, pero no aparece en la tensión de línea [HOL03] (ver Fig. 5.11).




Figura 5.10. Onda moduladora con inyección de un tercer armónico [HOL03].

Capítulo 5: Influencia de los convertidores de frecuencia en el diagnóstico de Motores de Inducción

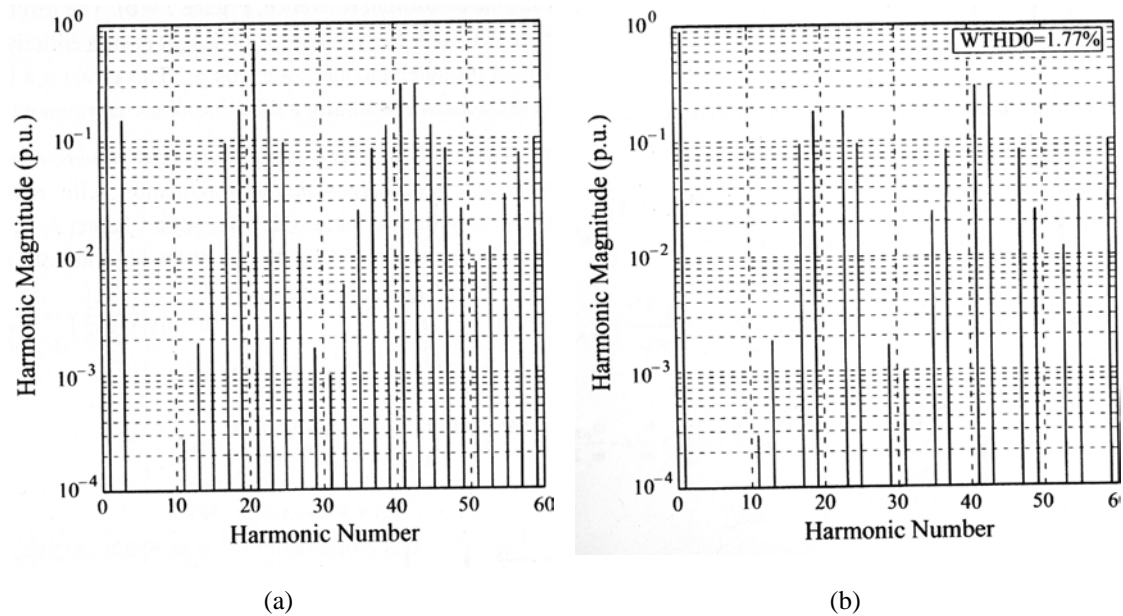


Figura 5.11. Contenido armónico de la tensión V_{AZ} (a) y V_{AB} (b) bajo el esquema de una PWM senoidal con inyección de un tercer armónico en la onda moduladora ($m_a = 0,9$ y $m_f = 21$) [HOL03].

5.2.6. Otro contenido armónico.

En [AMR08] se demuestra que, además de armónicos enteros de la frecuencia fundamental y de la frecuencia portadora, pueden aparecer interarmónicos, armónicos no enteros de las frecuencias anteriormente mencionadas, incluso por debajo de la frecuencia fundamental, cuyo filtrado es muy complicado. En dicho artículo se da una explicación a la generación de estos interarmónicos, que depende en gran medida del sistema de control usado. Ver Fig. 5.12.




Figura 5.12. Generación de interarmónicos en la corriente de salida de un convertidor de tensión tipo PWM [ARM08].

5.3. Efectos del uso del convertidor sobre el funcionamiento del accionamiento.

El uso de un convertidor de tensión para alimentar el motor tiene sus efectos positivos en cuanto ahorro energético, control más preciso de par y/o velocidad y corriente de arranque más reducida. Sin embargo, también presenta un lado negativo que va a tener un impacto sobre la vida útil del motor y también sobre las técnicas de diagnóstico.

Como ya se ha visto en apartados anteriores, la tensión de alimentación del motor, que es la tensión de salida del inversor, presenta un alto contenido armónico, incluso a frecuencias medias y altas. Este contenido armónico dependerá del esquema de modulación PWM adaptado por el fabricante del convertidor [HOL03], [WU06] y la estrategia de control seleccionada [SON10]. El motor de inducción no deja de ser una carga R-L (inductiva) para el convertidor, por lo que la propia máquina filtrará en la corriente bastante de este contenido armónico. Sin embargo, esta corriente supone la inyección de armónicos e interarmónicos en la tensión de la red que pueden producir efectos indeseados en otras cargas como resonancias, flicker, sobrecalentamiento, interferencias alrededor de la frecuencia de la onda portadora [CHA05], [ARM08], [GRO00].

A pesar de un posible filtrado del propio motor, la presencia de armónicos en la corriente seguirá siendo importante y afectará al motor, al accionamiento en su conjunto y a otras cargas alimentadas de la misma red. Estos efectos se resumen en los siguientes puntos:

- Pueden aparecer pares pulsantes y resonancias que, a su vez, pueden ser causa de fallos del eje por fatiga, reducción de su vida útil, fallos en rodamientos e, incluso bloqueos mecánicos del motor [PLO05], [SON09], [SON10a] y [SON10b].
- El motor va a ser más ruidoso y va a estar sometido a un mayor nivel de vibraciones mecánicas [CHA06], [CHO98], [PLO05], [SON10a] y [YAC95].
- Cada componente del espectro de la corriente va a producir pérdidas por efecto Joule adicionales, lo que supone un mayor calentamiento del motor.

- La tensión de alimentación del motor se va a caracterizar por unos gradientes muy elevados que pueden dañar el aislamiento eléctrico de la máquina [DUQ05a].

5.4. Efectos del uso del convertidor en el diagnóstico de fallas.

En el terreno del diagnóstico, la introducción del convertidor ha supuesto un gran cambio. Aparecen nuevos retos que necesitan una mayor investigación para ser superados. Entre los nuevos retos, o inconvenientes, que presenta el diagnóstico de motores de inducción alimentados por convertidor se pueden citar los siguientes:

- Elevado ruido en la señal. Al aplicar la FFT (o cualquier otra técnica numérica) a una señal, de tensión o corriente, procedente de un convertidor, en algunos casos se puede observar un nivel de ruido o césped muy elevado que puede reducir la posibilidad de observar o reconocer firmas o patrones característicos de las faltas del motor o máquina [AKI08a], [BRI08a]. El nivel de ruido dependerá del tipo de convertidor, del fabricante, estrategia de modulación, esquema de control, etc. En la Fig. 5.13 se ha representado el contenido armónico en baja frecuencia de la tensión de red en el laboratorio de Máquinas Eléctricas de la EII (UVA) alimentando un motor de jaula. Para comparar se ha representado en las Figs. 5.14 y 5.15 [MOR10] el contenido armónico de la tensión de línea del mismo motor alimentado por un convertidor Altivar 66 de Telemecánica. Se puede observar el incremento del césped o nivel ruido.
- La frecuencia fundamental puede variar dinámicamente, es decir, es posible que el motor no trabaje en estado estacionario el tiempo suficiente para poder emplear algunas de las técnicas que se usarán en este proyecto. El objetivo de emplear un convertidor es ajustar el par y/o velocidad desarrollado por el motor a los requerimientos de la máquina accionada. Dependiendo de la aplicación, puede suponer que el convertidor, de acuerdo con su tipo de control, vaya ajustando de forma continua la frecuencia, y si es necesario, también la amplitud, de la tensión de salida, según los requerimientos de la carga. Por ejemplo, muchos convertidores modernos tienen la opción de compensación por deslizamiento que incrementa la frecuencia de salida del convertidor si aumenta la carga del motor. Es decir, intentan mantener constante la velocidad de giro de

Capítulo 5: Influencia de los convertidores de frecuencia en el diagnóstico de Motores de Inducción

la máquina y no la frecuencia de consigna. De esta forma, una frecuencia de consigna de 50 Hz puede verse incrementada si el algoritmo de control, aunque sea en lazo abierto, detecta un deslizamiento elevado. El control decide incrementar la frecuencia por ejemplo a 51,5 Hz, para compensar en la velocidad ese incremento del deslizamiento (ver Figs. 5.14 a 5.17, como ejemplo [MOR10]). Estos cambios son más acusados si el control del convertidor es en lazo cerrado. Es más, algunos reguladores en lazo cerrado pueden llegar a suprimir (o atenuar) en el espectro algunos patrones característicos de ciertas faltas [AKI08b], [BEL00], [CUN07], [TAL03] y [WOL03].

- El convertidor introduce interarmónicos, incluso de baja frecuencia [ARM08], que pueden llegar a dificultar la observación de los patrones reales indicadores de fallo [JUN06] (ver Fig. 5.16 y 5.17 [MOR10]). Estos interarmónicos pueden ser de mayor amplitud que los indicadores de fallo y estar muy próximos a éstos en el espectro.

Lo comentado en estos tres puntos representa los principales inconvenientes que presenta el diagnóstico de motores de inducción alimentados por el convertidor [WIE99]. Esta línea de investigación es relativamente reciente, pero ya se están presentando resultados en la literatura especializada [DUQ05b], [BOS05], [YAN07], [DUQ04], incluso en estado transitorio [PON10], [RAJ07], pero se requiere una mayor profundización [AKI08a], [BEL08].




Figura 5.13. Contenido armónicos de la tensión de línea: alimentación directa de red [MOR10].

A pesar de los inconvenientes señalados, la operación con convertidores también puede presentar ventajas desde el punto de vista del diagnóstico. Como ya se ha comentado, el convertidor introduce en el espectro de la corriente un contenido armónico adicional. Aparecen armónicos temporales (de baja y media frecuencia) múltiplos enteros de la frecuencia fundamental. En algunos casos, con una amplitud muy importante comparada con el fundamental. En los motores asíncronos, la mayoría de los fallos, y en particular la rotura de barras en el rotor, se manifiesta como una serie de bandas alrededor del armónico fundamental y separadas simétricamente una distancia que dependen del deslizamiento. Este fenómeno o patrón también se repite alrededor de los armónicos temporales introducidos por el convertidor, añadiendo nuevos patrones que pueden facilitar el diagnóstico [DUQ12a], [DUQ12b], [DUQ11a], [DUQ11b], [GAR11a], [TOL13], [AKI08a]. Incluso, alrededor de algunos de estos armónicos, como puede ser el 5 (ver Fig. 5.18) y el 7 (ver Fig. 5.19), se ha demostrado que el fallo se manifiesta con anterioridad al armónico fundamental [BOS09], [DUQ11b], [DUQ10]. Es cierto, por tanto, que la utilización del convertidor se traduce en ciertos inconvenientes, pero también amplía el número de patrones o firmas en el espectro que pueden facilitar la detección del fallo y su posterior diagnóstico. Para superar los inconvenientes, es necesario ampliar el número de patrones a monitorizar (tanto en el dominio de la frecuencia como en el temporal) con el objetivo de asegurar una mayor eficiencia en el diagnóstico [GAR12], [AKI08a].




Figura 5.14. Contenido armónico de la tensión de línea: alimentación con variador Telemecánica Altivar 66, con una frecuencia de consigna de 35 Hz y la opción de compensación por deslizamiento activada [MOR10].

Capítulo 5: Influencia de los convertidores de frecuencia en el diagnóstico de Motores de Inducción




Figura 5.15. Contenido armónico de la tensión de línea: alimentación con variador Telemecánica Altivar 66, con una frecuencia de consigna de 65 Hz y la opción de compensación por deslizamiento activada. Ejemplo de sobremodulación [MOR10].

En la realización de este trabajo se utilizaron tres fuentes de alimentación que se analizan en la Fig. 5.20. Se alimentó el motor de inducción objeto de estudio directamente de la red del Laboratorio de Máquinas Eléctricas de la EII y también se emplearon dos convertidores comerciales con salida PWM: Micromaster 420 S de Siemens (4 kW), PowerFlex 40 de Allen Bradley (2 kW).




Figura 5.16. Contenido armónico de la tensión de línea: alimentación con variador Siemens Micromaster 420 S, con una frecuencia de consigna de 35 Hz y la opción de compensación por deslizamiento activada [MOR10].

Capítulo 5: Influencia de los convertidores de frecuencia en el diagnóstico de Motores de Inducción




Figura 5.17. Contenido armónico de la tensión de línea: alimentación con variador Siemens Micromaster 420 S, con una frecuencia de consigna de 65 Hz y la opción de compensación por deslizamiento activada. Ejemplo de sobremodulación [MOR10].

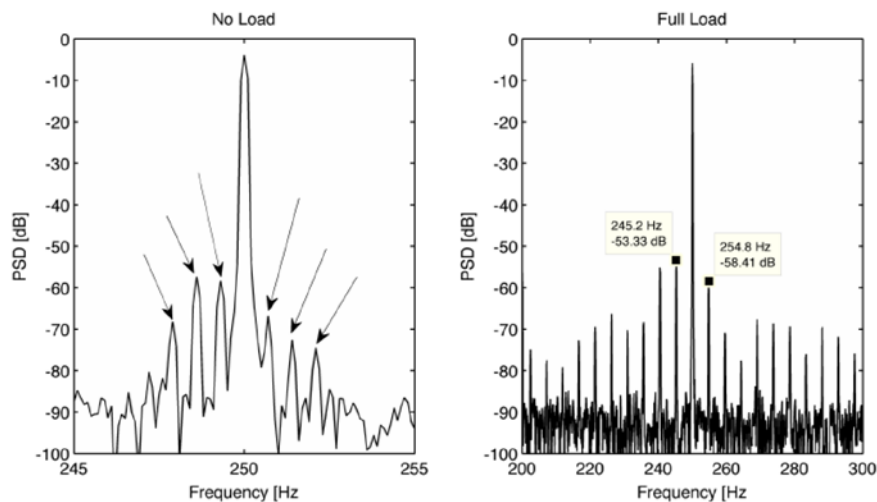


Figura 5.18. Contenido armónico alrededor del 5º armónico en un motor alimentado con una fuente programable y sufriendo un fallo de rotura de barra [DUQ11a].

En la primera fila de la Fig. 5.20 se ha representado la forma de onda de la tensión de línea para las tres fuentes. Los dos variadores tienen una frecuencia de salida de 50 Hz y la opción de compensación por deslizamiento desactivada. De esta forma, la frecuencia de consigna y la frecuencia real coinciden. Lo primero que puede llamar la atención es la forma de onda de la tensión de red que se aleja de forma importante de una forma de onda senoidal perfecta. Los dos variadores son de tipo PWM con la misma frecuencia de conmutación a 4 kHz. Esta frecuencia es la de la onda portadora y en ambos

Capítulo 5: Influencia de los convertidores de frecuencia en el diagnóstico de Motores de Inducción

variadores se puede fijar a voluntad. El valor por defecto es de 4 kHz. En la segunda fila de la figura se ha representado la transformada de Fourier normalizada de las tensiones de línea anteriores. Se observa que los dos variadores introducen armónicos de gran valor alrededor de la frecuencia de la onda portadora y de sus múltiplos enteros. Se observa que la estrategia de modulación es diferente en ambos convertidores puesto que el contenido armónico es diferente.

En la tercera línea se ha representado un detalle de la transformada de Fourier de la tensión de línea en el rango 0 a 400 Hz y se ha superpuesto también la misma transformada de la corriente que consumía el motor durante la realización del ensayo. Se observa el efecto de la deformación de la onda de tensión de Red por la aparición de armónicos enteros de la frecuencia fundamental. También se observa la aparición de armónicos enteros del fundamental e interarmónicos en las dos figuras correspondientes a los variadores. Hay que destacar que este contenido armónico es mayor en el variador Siemens, como se observa mejor en la última fila de la figura, donde se ha representado la Densidad de Potencia Espectral (PSD) de las mismas señales para destacar los valores más pequeños. Este contenido armónico en tensión, en algunos casos, también se refleja en la corriente, lo que puede dificultar en algunos casos la identificación de algunos indicadores de fallo.




Figura 5.19. Contenido armónico alrededor del armónico 5 y 7 de un motor alimentado por convertidor y una barra rota [BOS09].

Capítulo 5: Influencia de los convertidores de frecuencia en el diagnóstico de Motores de Inducción

Se puede concluir que, desde el punto de vista del diagnóstico de fallas en el motor, el principal cambio debido al convertidor de potencia es la introducción en el espectro de la corriente de un contenido armónico adicional. Esto, en algunos casos dificulta el reconocimiento de las señales de falla, sobre todo incipientes, pero, al mismo tiempo, este contenido armónico adicional puede evidenciar nuevas señales de falla que no estaban presentes con alimentación de red o con un convertidor diferente. Considerando todo esto, es importante considerar la influencia del convertidor de potencia a la hora de analizar el problema de diagnóstico de fallas en motores de inducción.

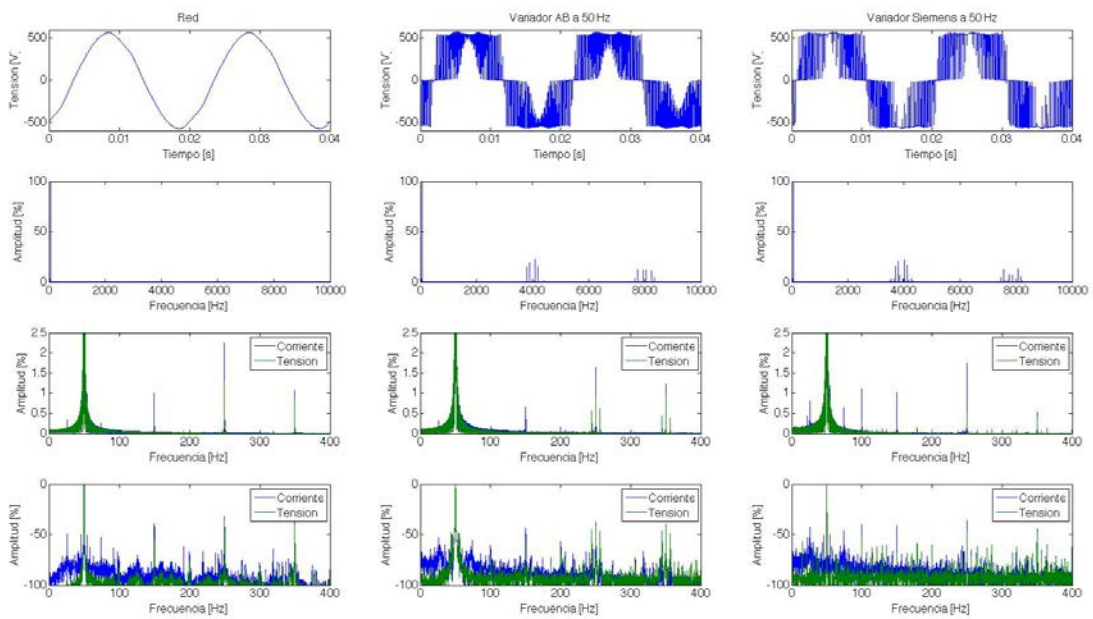


Figura 5.20. Contenido armónico de la tensión de línea y corriente de las tres fuentes de alimentación empleadas en este trabajo.

6. Propuesta de metodología de diagnóstico de barras rotas en motores de inducción orientada al mantenimiento.

6.1 Introducción

En el presente capítulo se presenta la metodología propuesta para el diagnóstico de barras rotas en motores de inducción. Siguiendo el esquema de monitorización presentado en el capítulo 3, primeramente se describe la señal a ser medida, seguidamente se explica qué técnicas se utilizan para extraer las características de fallo de la señal original. A continuación se muestra el esquema seguido para reducir la dimensionalidad de los datos y seleccionar las características más relevantes para la clasificación. Seguidamente se muestra la metodología para comparar los métodos de diagnóstico empleados en el presente trabajo. Finalmente se explica el enfoque del diagnóstico en función de la criticidad o importancia del motor dentro de la cadena productiva.

6.2 Señales a medir

La principal señal utilizada en este trabajo es la corriente estatórica. Simultáneamente, también se midió la velocidad y la tensión de fase (aunque esta señal no se ha empleado para el diagnóstico).

La velocidad medida fue utilizada para estimar inicialmente el deslizamiento. Aunque posteriormente se calculó el deslizamiento real mediante la ubicación de los armónicos de ranura en el espectro de la corriente. De esta forma, hallado el armónico de ranura en el espectro se puede calcular con mayor fiabilidad el deslizamiento del motor, así como la velocidad.

De esta forma las características utilizadas para el diagnóstico en esta tesis se pueden dividir en tres grandes grupos:

- 1) Características indicativas del nivel de carga del motor: Dentro de este grupo se encuentran la velocidad, el deslizamiento y el valor eficaz de la corriente del motor.
- 2) Características obtenidas del espectro de la corriente estatórica: Este segundo grupo se puede volver a dividir en dos:

Capítulo 6: Propuesta de metodología de diagnóstico de barras rotas en Motores de Inducción orientada al mantenimiento

- a. características obtenidas directamente de la transformada de Fourier,
 - b. características obtenidas mediante la transformada de Hilbert.
- 3) Características estadísticas en el dominio del tiempo: para este grupo se eligieron un total de 15 valores entre los propuestos por la literatura. Aunque este tipo de características están más difundidas en el diagnóstico de máquinas eléctricas utilizando señales de vibraciones [PAY02], [ZAE12], también se han propuesto algunas aplicaciones que consideran la corriente en el dominio temporal como señal de entrada [VAN09], [GHA10].

6.3 Procesamiento de la señal para extracción de patrones

6.3.1 Características indicativas del nivel de carga del motor

Como ya se ha indicado en 2.3.2, la magnitud de algunas características de fallo por barra rota, como pueden ser las bandas laterales, aumentan con el nivel de carga del motor. El objetivo del presente trabajo es diagnosticar el estado del motor en cualquier nivel de carga. Por eso, es esencial aportar esta información al sistema de diagnóstico. Como características indicativas de este nivel de carga, se consideran las siguientes variables:

- 1) Deslizamiento
- 2) Corriente (valor eficaz)
- 3) Velocidad

En los casos del deslizamiento y de la velocidad, se consideraron los valores calculados en base al armónico de ranura.

6.3.2 Características obtenidas del espectro de la corriente

Las características obtenidas del espectro de la corriente son las amplitudes de los armónicos explicados en la sección 3.4.2. De acuerdo a la forma en que son obtenidas estas amplitudes, se pueden subdividir las características del espectro de corriente utilizadas en esta tesis en las obtenidas por la Transformada de Fourier, y las obtenidas por la Transformada de Hilbert.

a) Características obtenidas mediante la Transformada de Fourier.

Las características del espectro de la corriente son obtenidas de la estimación de la amplitud de las bandas laterales alrededor del 1^{er} armónico, 5^{to} armónico y 7^{mo} armónico. Se calculó el *Power Spectral Density* (PSD) normalizado, de donde se obtuvo la amplitud de cuatro bandas laterales alrededor del 1^{er} armónico, dos alrededor del 5^{to} armónico y dos alrededor del 7^{mo} armónico. La nomenclatura y la frecuencia a la que encuentra cada banda lateral se resumen en la Tabla 6.1, donde s es el deslizamiento y f_1 la frecuencia fundamental.

Tabla 6.1 Características del espectro de la corriente obtenidas mediante la Transformada de Fourier.

<u>Banda lateral</u>	<u>Nomenclatura</u>	<u>Frecuencia</u>
1 ^{er} armónico, 1 ^{ra} banda inferior	BI	$f_{bi} = (1 - 2s)f_1$
1 ^{er} armónico, 2 ^{da} banda inferior	BI2	$f_{bi2} = (1 - 4s)f_1$
1 ^{er} armónico, 1 ^{ra} banda superior	BS	$f_{bs} = (1 + 2s)f_1$
1 ^{er} armónico, 2 ^{da} banda superior	BS2	$f_{bs2} = (1 + 4s)f_1$
5 ^{to} armónico, 1 ^{ra} banda inferior	B5I	$f_{b5i} = (5 - 2s)f_1$
5 ^{to} armónico, 1 ^{ra} banda superior	B5S	$f_{b5s} = (5 + 2s)f_1$
7 ^{mo} armónico, 1 ^{ra} banda inferior	B7I	$f_{b7i} = (7 - 2s)f_1$
7 ^{mo} armónico, 1 ^{ra} banda superior	B7S	$f_{b7s} = (7 + 2s)f_1$

La medición de la velocidad del rotor puede sufrir ligeras variaciones debido a errores de medición, pequeñas fluctuaciones en la alimentación o en la carga. Es de resaltar que normalmente las mediciones con pequeñas variaciones son descartadas en la mayoría de los esquemas de diagnóstico debido a que la transformada de Fourier requiere mediciones en condiciones totalmente estables y estas variaciones podrían generar errores en el proceso de cálculo de características. En esta tesis se decidió sólo repetir los ensayos con una variación apreciable por dos motivos, uno es que se adoptó la hipótesis de que en la industria o casos reales de diagnóstico, a menudo es bastante difícil obtener una medición completamente estable durante el tiempo requerido para muestrear el ensayo. Considerando esto, el no descartar ensayos con muy ligeras variaciones aporta una aproximación más realista de un conjunto de muestras tomadas en la industria. Por otro lado, el considerar estos ensayos con ligeras variaciones constituye una forma de probar la robustez de los algoritmos ante este tipo de datos de entrada con pequeños errores de muestreo, por lo que los resultados serían más

Capítulo 6: Propuesta de metodología de diagnóstico de barras rotas en Motores de Inducción orientada al mantenimiento

semejantes a los que se obtendrían si el método se aplicase con datos obtenidos de motores en la industria, y no sólo en el ambiente controlado del laboratorio.

En estos casos, el pico correspondiente a la banda lateral relativa al fallo podría estar ligeramente desfasado con respecto a las ecuaciones de la Tabla 6.1. Considerando esto, para calcular las amplitudes se buscó el pico del PSD con centro en la frecuencia teórica y relativa al fallo calculada (f_b). La búsqueda se realizó en un rango con radio de 1 Hz alrededor de esta frecuencia, siempre y cuando la distancia entre f_b y f_l fuese mayor a 1 Hz. Si la diferencia entre f_b y f_l está comprendida entre 0,5 y 1 Hz, el radio de búsqueda del pico se reducía a 0,4 Hz. Finalmente, si la distancia entre f_b y f_l es menor a 0,5 Hz, se utiliza directamente la amplitud correspondiente a f_b .

b) Características obtenidas mediante la transformada de Hilbert

Recordando la ecuación (2.31) que define la Señal Analítica:

$$\vec{i}_b(t) = [1 + \beta \cos(\varpi_0 t)] I_m (\cos(\varpi t) + j \text{sen}(\varpi t)) = [1 + \beta \cos(\varpi_0 t)] I_m e^{j \varpi} \quad (6.1)$$

donde β denota la profundidad de modulación (índice de modulación) y $\omega_0 = 2\pi f_0$. I_m es la corriente de la máquina. La deducción de esta ecuación se presentó en la sección 2.4.2.2.

El uso del módulo de la Señal Analítica como característica para el diagnóstico de fallos en motores de inducción se ha centrado en las ventajas que presenta para discernir claramente la primera banda lateral superior relacionada con barras rotas, $\omega_0 = 2\pi(2sf_l)$ [PUC09]. Sin embargo, la ecuación (6.1) puede usarse para localizar cualquier componente característica de fallo, siempre que esté localizada a una frecuencia positiva, mayor que la fundamental. Considerando esto, en este trabajo se propone estudiar la factibilidad y eficiencia de utilizar el módulo de la Señal Analítica para calcular otras componentes de fallo a frecuencias superiores a $\omega_0 = 2\pi(2sf_l)$, como podría ser $\omega_1 = 2\pi(4sf_l)$, la segunda banda lateral alrededor del primer armónico, o $\omega_{2,3} = 2\pi((4 \pm 2s)f_l)$, o $\omega_{4,5} = 2\pi((6 \pm 2s)f_l)$, las bandas laterales alrededor de los armónicos 5^{to} y 7^{mo} respectivamente.

La Tabla 6.2 muestra las características del Módulo de la Señal Analítica elegidas como indicativas de fallo que se utilizarán en este trabajo con su respectiva nomenclatura y frecuencia.

Capítulo 6: Propuesta de metodología de diagnóstico de barras rotas en Motores de Inducción orientada al mantenimiento

Tabla 6.2 Características del espectro de la corriente obtenidas mediante la Transformada de Hilbert.

<u>Banda lateral</u>	<u>Nomenclatura</u>	<u>Frecuencia</u>
1 ^{er} armónico, 1 ^{ra} banda superior	HS	$f_{hs} = 2sf_1$
1 ^{er} armónico, 2 ^{da} banda superior	HS2	$f_{hs2} = 4sf_1$
5 ^{to} armónico, 1 ^{ra} banda inferior	H5I	$f_{h5i} = (4 - 2s)f_1$
5 ^{to} armónico, 1 ^{ra} banda superior	H5S	$f_{h5s} = (4 + 2s)f_1$
7 ^{mo} armónico, 1 ^{ra} banda inferior	H7I	$f_{h7i} = (6 - 2s)f_1$
7 ^{mo} armónico, 1 ^{ra} banda superior	H7S	$f_{h7s} = (6 + 2s)f_1$

Para calcular la Transformada de Hilbert hay que integrar de $-\infty$ a $+\infty$ la ecuación (6.2). En la práctica se trabaja con una frecuencia de muestreo finita y se calcula la Transformada Discreta de Hilbert (TDH) usando un procedimiento de Transformada Rápida de Fourier (TRF) [MAR99]. Este proceso de discretización produce un rizado en el módulo de la Señal Analítica cerca de los extremos del intervalo de muestreo. Para evitar este problema, tal como se propone en [PUC09], sólo se utilizan la mitad de los puntos del módulo de la Señal Analítica, los puntos centrales, para calcular las características de fallo mostradas en la Tabla 6.2.

6.3.3 Características estadísticas en el dominio del tiempo

Varias características estadísticas tomadas directamente de la onda temporal, tanto de señales de vibración [PAY02], [ZAE12] como de corriente [VAN09], [GHA10] han sido propuestas como indicadores de fallos en motores de inducción. Para la clasificación se han utilizado técnicas de reconocimiento de patrones, redes neuronales o clasificadores estadísticos.

De estas características, se eligieron inicialmente 15 valores estadísticos para ser utilizados en el diagnóstico de barras rotas en motores de inducción. Estas características, con sus respectivas fórmulas, se pueden ver en la Tabla 6.3.

Algunas de las características estadísticas consideradas tienen una interpretación geométrica sencilla, como se vio en la sección 2.4.1, mientras que otras son útiles para el diagnóstico, pero no tienen una interpretación sencilla.

Así, el primer momento es simplemente el promedio de la señal. El segundo momento es la desviación estándar o desviación típica. Esta desviación estándar es una medida de dispersión que refleja cuánto tienden a alejarse los valores concretos del promedio en

Capítulo 6: Propuesta de metodología de diagnóstico de barras rotas en Motores de Inducción orientada al mantenimiento

una distribución. Específicamente, la desviación típica es "el promedio del cuadrado de la distancia de cada punto respecto del promedio".

Tabla 6.3 Características estadísticas seleccionadas.

	<u>Característica estadística</u>	<u>Ecuación</u>	<u>Nomenclatura</u>
1	Momento de 1 ^{er} Orden (Promedio).	$m_1 = \frac{1}{n} \sum (x)$	1 ^{er} M
2	Momento de 2 ^{do} Orden (Varianza).	$m_2 = \frac{1}{n} \sum (x - \bar{x})^2$	2 ^{do} M
3	Momento de 3 ^{er} Orden.	$m_3 = \frac{1}{n} \sum (x - \bar{x})^3$	3 ^{er} M
4	Momento de 4 ^{to} Orden.	$m_4 = \frac{1}{n} \sum (x - \bar{x})^4$	4 ^{to} M
5	Momento de 6 ^{to} Orden Normalizado.	$m_6 = \frac{1}{(n * m_2)} \sum (x - \bar{x})^6$	6 ^{to} M
*	Cumulante de 1 ^{er} Orden.	$c_1 = m_1$	
6	Cumulante de 2 ^{do} Orden.	$c_2 = m_2 - m_1^2$	2 ^{do} C
7	Cumulante de 3 ^{er} Orden.	$c_3 = m_3 - 3m_1m_2 + 2m_1^3$	3 ^{er} C
8	Cumulante de 4 ^{to} Orden.	$c_4 = m_4 + m_3m_1 - 3m_2^2 + 12m_2m_1^2 - 6m_1^4$	4 ^{to} C
9	Skewness o asimetría.	$Skew = \frac{m_3}{(\sqrt{m_2})^3}$	Skew
10	Curtosis.	$Curt = \frac{m_4}{(\sqrt{m_2})^4}$	Curt
11	Promedio de valores absolutos.	$ \bar{x} = \frac{1}{n} \sum x $	PVA
12	Máximo valor absoluto.	$x_p = \max x $	MVA
13	Valor cuadrático medio.	$x_r = \left(\frac{1}{n} \sum \sqrt{ x } \right)^2$	VCM
**	Valor eficaz o RMS (<i>Root Mean Square</i>)	$X_{rms} = \sqrt{\frac{1}{N} \sum (x - \bar{x})^2}$	
14	Factor de Cresta.	$f_c = \frac{x_p}{x_{rms}}$	FC
15	Factor de forma.	$f_f = \frac{x_{rms}}{ \bar{x} }$	FF

* se incluye únicamente para indicar que el 1^{er} Cumulante es igual al 1^{er} momento, por lo que no representa una nueva característica y ** tampoco es una característica nueva porque representa al valor eficaz ya considerado como característica relacionada al nivel de carga del motor.

En la Fig. 6.3 se esquematiza el proceso de obtención de las características consideradas en este trabajo.

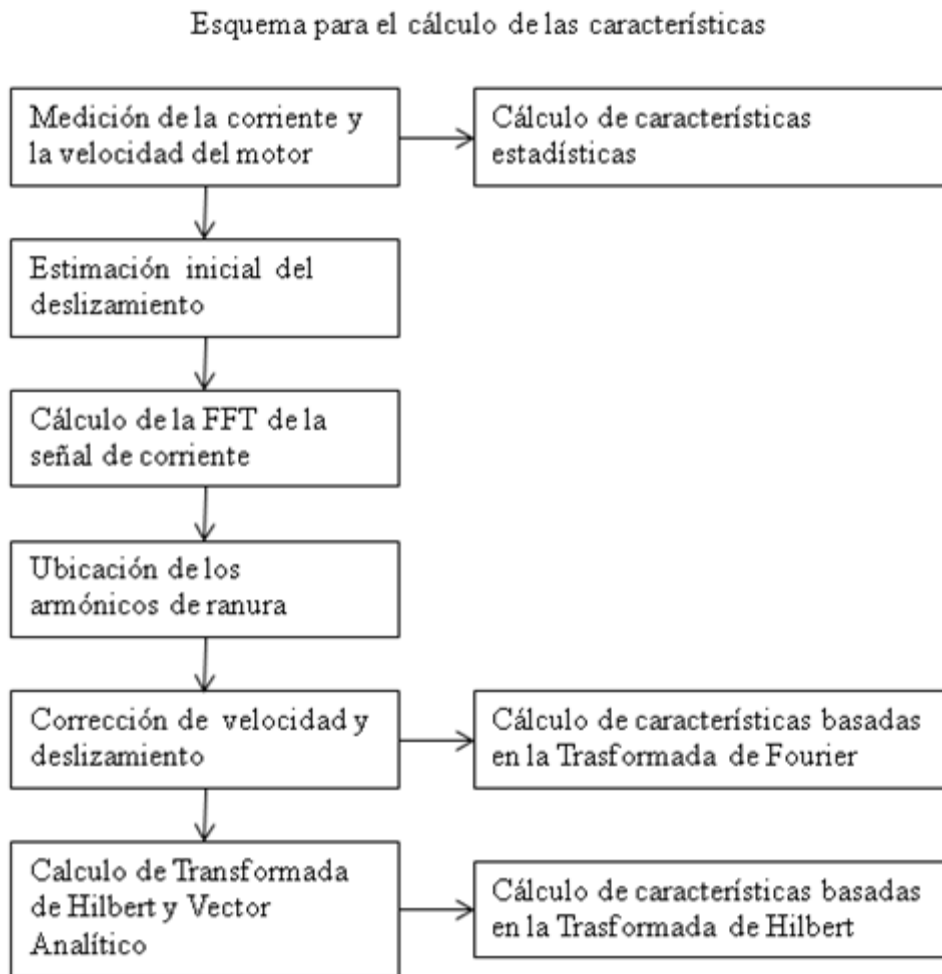


Figura 6.3. Esquema del proceso de cálculo de las características.

6.4 Método de diagnóstico, basado en Redes Neuronales Artificiales y comparado con Análisis Discriminante y Regresión Logística.

En el presente trabajo se compara el desempeño de tres técnicas para el diagnóstico de fallos, dos de naturaleza estadística, el Análisis Discriminante y la Regresión Logística, y tres de inteligencia artificial, Redes Neuronales Artificiales simples, Ensamble de 10 redes neuronales (Ensamble de 10 ANN) y Ensamble de 3 redes neuronales (Ensamble de 3 ANN).

El diagnóstico de fallos en motores de inducción es un problema que ha sido ampliamente estudiado y que ha demostrado ser una importante pero complicada tarea en el área de la ingeniería eléctrica [MOH11]. A lo largo de los años se han propuesto

Capítulo 6: Propuesta de metodología de diagnóstico de barras rotas en Motores de Inducción orientada al mantenimiento

diversas metodologías para resolver este problema. En el capítulo 3 se ha mostrado que técnicas de inteligencia artificial como las redes neuronales han sido exitosamente empleadas para resolver problemas similares a los que encara esta tesis. Considerando esto, en este trabajo se propone emplear un ensamble de redes neuronales para diagnosticar roturas incipientes en motores de inducción.

Para comparar el rendimiento de la metodología propuesta se emplearán dos técnicas estadísticas ampliamente conocidas:

- a) **Análisis Discriminante:** se seleccionó por su simplicidad y eficiencia. Además, está demostrado que puede clasificar correctamente un conjunto multiclase, siempre que exista una separación lineal entre las clases o grupos [MAR07]. Es un método sencillo y computacionalmente eficiente, una vez seleccionadas las características y entrenado el método solamente es necesario calcular la ecuación (4.1) para clasificar a un nuevo ensayo. Sin embargo como solamente puede establecer separaciones lineales entre los grupos o clases, no es capaz de clasificar correctamente cuando están presentes relaciones no lineales entre las características.
- b) **Regresión Logística:** se eligió esta técnica por poder aproximar relaciones curvilíneas [PAM00], es decir, puede considerar relaciones no lineales para establecer límites de separación con curvatura entre los grupos considerados. Esta capacidad le da cierta ventaja con respecto al Análisis Discriminante cuando no existe una separación lineal entre las clases, pues, tal como se explicó en la sección 4.2.3, el Análisis Discriminante subestima la dependencia real entre las variables en la parte media de la curva y la sobreestima en los extremos, por lo que tiene dificultad de clasificar correctamente cuando hay relaciones muy complejas entre las variables.

Considerando esto, se espera que, en los casos que haya una separación lineal todos los algoritmos considerados consigan rendimientos muy altos. Sin embargo, en los casos que se presenten relaciones más complejas entre las características, se espera que los métodos basados en redes neuronales superen a los estadísticos y que la Regresión Logística obtenga un mejor rendimiento que el Análisis Discriminante.

6.4.1 Reducción de la dimensionalidad de los datos

Inicialmente se eligieron un total de 3 características indicativas del nivel carga, 14 características del espectro de la corriente estática y 15 valores estadísticos del dominio del tiempo de la onda de la corriente. Sin embargo, no todas estas características son imprescindibles para realizar un correcto diagnóstico. Así, podría haber características muy correlacionadas entre sí, que podrían ser eliminadas sin reducir la eficiencia de los métodos de diagnóstico. Tampoco es seguro que todas las características tengan capacidad discriminante en todos los casos estudiados. Es decir, algunas características podrían no mostrar una variación significativa con el estado de fallo del motor por lo que no serían de utilidad para la clasificación.

Considerando esto, se redujo la dimensionalidad de los datos de entrada para los algoritmos de clasificación en un proceso de 2 pasos:

- a) Eliminación de variables con alta correlación: asumiendo la hipótesis de que características con una correlación alta aportan la misma información al proceso de diagnóstico, se agruparon las características con una correlación de 0,9 o más. De cada grupo de variables altamente correlacionadas se eligió una característica como representativa del grupo.
- b) Reducción de variables por Análisis Discriminante: se utilizó el Análisis Discriminante para determinar qué características tenían un valor discriminante más elevado y se utilizaron las características seleccionadas por el método, como más relevantes para la clasificación. Se ejecutó la selección de variables con Análisis Discriminante por pasos hacia adelante y por pasos hacia atrás, y en caso de no obtenerse resultados iguales, se eligió al conjunto de variables que obtuvo la mejor clasificación.

Cabe resaltar que la reducción de la dimensionalidad tiene como objetivo disminuir el esfuerzo computacional sin reducir significativamente el rendimiento de los métodos de diagnóstico.

6.4.2 Comparación de desempeño de los algoritmos.

Los algoritmos fueron probados con dos grupos de datos:

- i) todas las características inicialmente elegidas, y

Capítulo 6: Propuesta de metodología de diagnóstico de barras rotas en Motores de Inducción orientada al mantenimiento

- ii) solamente con las características seleccionadas como relevantes por el Análisis Discriminante.

Se compararon los resultados para comprobar que la reducción del número de variables no afecta significativamente el desempeño de los algoritmos.

Para comprobar la capacidad de generalización de los algoritmos propuestos, es decir, la capacidad de clasificar correctamente también los ensayos que no se han utilizado en su proceso de entrenamiento, generalmente se separan los datos de ensayos en grupos de entrenamiento y validación. El inconveniente de realizar una sola prueba es que el desempeño de los métodos de clasificación puede variar de acuerdo a la forma en que los datos de entrada fueron separados en grupos de entrenamiento y validación. Esto resta robustez al procedimiento, cuya eficacia sería dependiente de esta división de los datos.

	División de los datos									
	Grupo1	Grupo2	Grupo3	Grupo4	Grupo5	Grupo6	Grupo7	Grupo8	Grupo9	Grupo10
Iteración 1	Entren.	Entren.	Entren.	Entren.	Entren.	Entren.	Entren.	Entren.	Entren.	<i>Validac</i>
Iteración 2	Entren.	Entren.	Entren.	Entren.	Entren.	Entren.	Entren.	Entren.	<i>Validac</i>	Entren.
Iteración 3	Entren.	Entren.	Entren.	Entren.	Entren.	Entren.	Entren.	<i>Validac</i>	Entren.	Entren.
Iteración 4	Entren.	Entren.	Entren.	Entren.	Entren.	Entren.	<i>Validac</i>	Entren.	Entren.	Entren.
Iteración 5	Entren.	Entren.	Entren.	Entren.	Entren.	<i>Validac</i>	Entren.	Entren.	Entren.	Entren.
Iteración 6	Entren.	Entren.	Entren.	Entren.	<i>Validac</i>	Entren.	Entren.	Entren.	Entren.	Entren.
Iteración 7	Entren.	Entren.	Entren.	<i>Validac</i>	Entren.	Entren.	Entren.	Entren.	Entren.	Entren.
Iteración 8	Entren.	Entren.	<i>Validac</i>	Entren.	Entren.	Entren.	Entren.	Entren.	Entren.	Entren.
Iteración 9	Entren.	<i>Validac</i>	Entren.	Entren.	Entren.	Entren.	Entren.	Entren.	Entren.	Entren.
Iteración 10	<i>Validac</i>	Entren.	Entren.	Entren.	Entren.	Entren.	Entren.	Entren.	Entren.	Entren.

Figura 6.4 Esquema de validación cruzada 10-fold. Los datos de entrada se dividen en 10 grupos y se realizan 10 iteraciones del algoritmo. En cada iteración 9 grupos se usan para entrenamiento (Entren.) y 1 grupo diferente para validación (Validac.). Finalmente se promedia el resultado.

Para comparar el desempeño de los algoritmos considerados, sin que la forma en que los datos fueron divididos en entrenamiento y validación sesgue artificialmente el resultado, se utilizó un esquema de validación cruzada 10-fold o de 10 iteraciones. Este esquema consiste en dividir los datos de entrada del algoritmo en 10 grupos de forma aleatoria. En el presente trabajo se decidió que la división sea semi-aleatoria pues se aseguró que cada grupo de datos tenga aproximadamente la misma proporción de clases o estados de fallo considerados que el total de los ensayos. Con estos 10 grupos se realizan 10 ejecuciones de los algoritmos y al final se promedian los 10 resultados para obtener el desempeño del algoritmo. Para cada ejecución del algoritmo o iteración del esquema de validación cruzada, se eligen 9 grupos de datos para entrenar el algoritmo y 1 grupo

Capítulo 6: Propuesta de metodología de diagnóstico de barras rotas en Motores de Inducción orientada al mantenimiento

para validar el resultado del método. La Fig. 6.4 muestra el esquema de validación cruzada utilizado. Con este método de evaluación del desempeño de los algoritmos se logra que cada ensayo sea utilizado para validar el algoritmo en alguna iteración y para entrenar el algoritmo en las otras iteraciones.

Es conveniente recordar que las técnicas estadísticas de clasificación utilizadas en esta tesis, Análisis Discriminante y Regresión Logística, son deterministas, es decir, con el mismo grupo de entrenamiento y mismo grupo de validación el resultado de la clasificación es siempre el mismo, independientemente del número de veces que se ejecute el algoritmo. En cambio, el desempeño de las Redes Neuronales Artificiales depende de la inicialización aleatoria de los pesos sinápticos. Por lo tanto, al ejecutarse el algoritmo en diferentes ocasiones, con inicializaciones aleatorias diferentes, el resultado varía, aun utilizándose el mismo grupo de datos de entrenamiento y de validación. Por esta razón las ANN fueron entrenadas 10 veces para cada iteración del esquema de validación cruzada, por lo tanto se realizaron 100 ejecuciones de las redes neuronales por grupo de pruebas. Para obtener la misma cantidad de ejecuciones diferentes del Análisis Discriminante y de la Regresión Logística se repitió el esquema de validación 10 veces con cada uno, es decir, también se consideraron 100 ejecuciones diferentes del Análisis Discriminante y de la Regresión Logística pero con 10 divisiones diferentes de los datos.

6.4.3 Cálculo del porcentaje de clasificación correcta ponderado.

Un algoritmo que clasifique todos los ensayos como pertenecientes al grupo con mayor cantidad de ensayos podría tener un porcentaje de clasificación elevado sin ser necesariamente bueno. Por ejemplo, en un desierto donde sólo llueve unos 10 días al año, un método que simplemente prediga “Día sin lluvia” todos los días obtendría un porcentaje de clasificación muy elevado pero no tendría ninguna utilidad. Debido a esto, para comparar el desempeño de los algoritmos de clasificación se utiliza el porcentaje de clasificación ponderado de acuerdo al ratio de cada clase con respecto al total de ensayos. Al no tener la misma cantidad de ensayos de cada clase, es decir, al no haber la misma cantidad de ensayos de motores sanos, con fallo leve, medio o barra totalmente rota, se debe dar más importancia a clasificar correctamente a las ensayos correspondientes a las clases con menos ensayos. Por esto se utiliza la ecuación (6.2) para calcular el porcentaje de clasificación correcta.

Capítulo 6: Propuesta de metodología de diagnóstico de barras rotas en Motores de Inducción orientada al mantenimiento

$$CC = \frac{\sum \frac{n_i}{r_i}}{\sum \frac{N_i}{r_i}} \quad (6.2)$$

donde:

- CC : es el porcentaje de clasificación correcta ponderado.
- n_i : es el número de ensayos de la clase i correctamente clasificados.
- r_i : es el ratio entre el número de ensayos correspondientes a la clase i y el número total de ensayos.
- N_i : es el número total de ensayos considerados.

Como se puede observar en (6.2), el número de clasificaciones correctas de cada clase es dividido por el ratio de dicha clase y el total, por lo tanto, como las clases con menos ensayos tienen ratios más bajos, estas clases tienen mayor peso al calcular el desempeño del algoritmo.

6.4.4 Grupos de pruebas de acuerdo al tipo de alimentación

Considerando que se realizaron ensayos con alimentación de red (50 Hz) y con diversos variadores a 35 Hz, 50 Hz y 65 Hz se hicieron los siguientes grupos de pruebas:

- 1) Se utilizaron todos los datos obtenidos de los ensayos con alimentación de red y variador a 35 Hz, 50 Hz y 65 Hz. Es decir, se utilizaron todos los ensayos para entrenar y validar los algoritmos.
- 2) Se utilizaron únicamente los ensayos obtenidos con alimentación de red.
- 3) Se utilizaron todos los ensayos obtenidos a la misma frecuencia. Es decir, se hicieron tres grupos de pruebas, uno con todos los ensayos a 35 Hz, otro con todos los ensayos a 50 Hz (red y variador) y un tercer grupo con todos los ensayos a 65 Hz.
- 4) Se asociaron en grupos a todos los ensayos obtenidos con un mismo variador a las diferentes frecuencias, 35 Hz, 50 Hz y 65 Hz.
- 5) Finalmente se efectuó un grupo de pruebas con cada variador a cada frecuencia por separado. Es decir, un grupo de pruebas con los ensayos de cada variador a 35 Hz, un grupo de pruebas con cada variador a 50 Hz y un grupo de pruebas con los ensayos de cada variador a 65 Hz.

Este estudio se repitió para los dos motores objeto de análisis.

Capítulo 6: Propuesta de metodología de diagnóstico de barras rotas en Motores de Inducción orientada al mantenimiento

Cabe resaltar que el diagnóstico de ensayos obtenidos con alimentadores diferentes y a frecuencias distintas representa un reto para los algoritmos. En el capítulo 7 se presenta un estudio previo de las variables indicativas de fallo donde se comprueba la relación no lineal de varias de ellas lo que significa una complicación más para los métodos de diagnóstico.

6.4.5 Esquema de monitorización propuesto

Recordando el esquema de la teoría generalizada de la monitorización de estado, (Fig. 3.1), en el presente trabajo se propone el esquema de trabajo detallado en la Fig. 6.5.

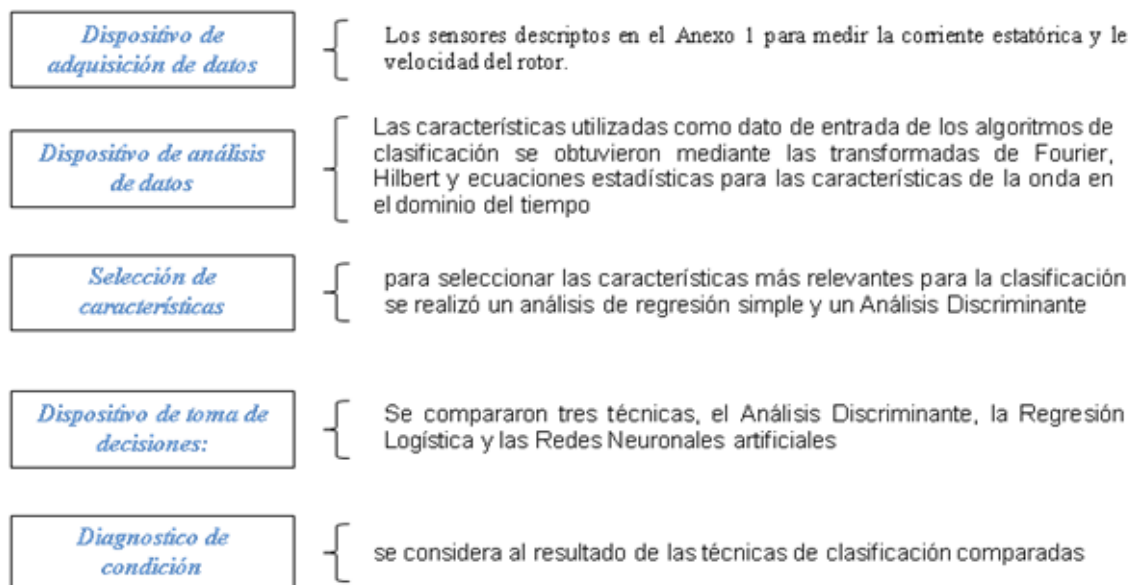


Figura 6.5 Esquema de monitorización propuesto.

6.5 Enfoque del diagnóstico en función de la importancia de los motores.

Desde un punto de vista académico, es importante poder diagnosticar si un motor está sano, tiene un fallo leve, moderado o un fallo grave. En el caso en estudio en este trabajo, se considera como fallo grave una barra totalmente rota. Así, es importante poder diferenciar, lo mejor posible, entre los distintos estados de fallo del motor, o clases consideradas.

Sin embargo, desde el punto de vista del encargado de mantenimiento en un ambiente industrial, la pregunta a contestar es si la máquina puede seguir operando normalmente hasta la próxima revisión, si debe ser sometida a mantenimiento en la siguiente parada

Capítulo 6: Propuesta de metodología de diagnóstico de barras rotas en Motores de Inducción orientada al mantenimiento

programada, o debe ser reparada inmediatamente. Por lo tanto, a veces le será de utilidad poder clasificar a la máquina en varios niveles de fallo, pero en otras ocasiones le importará más saber si el motor está sano o ya tiene una rotura de barra total.

La Fig. 6.6 explica gráficamente el diagnóstico del motor enfocado al mantenimiento predictivo y en función de su importancia.

<u>Diagnóstico del motor en función de su importancia</u>			
<u>Tipo de motor</u>	<u>Estados de fallo considerados</u>	<u>Acción a tomar</u>	<u>Nomenclatura</u>
Caso general	<ul style="list-style-type: none"> Motor Sano Fallo Leve Fallo Medio Barra Rota 	Estudiar en cada caso	F ₁₂₃
Motor de muy alta importancia	Motor Sano	Motor Sano	Ninguna
	Motor con fallo	<ul style="list-style-type: none"> Fallo Leve Fallo Medio Barra Rota 	Mantenimiento rápido
Motor de alta importancia	Sano o con avería menor	<ul style="list-style-type: none"> Motor Sano Fallo Leve 	Ninguna
	Motor con fallo medio o mayor	<ul style="list-style-type: none"> Fallo Medio Barra Rota 	Mantenimiento tan pronto sea posible
Motor baja importancia	Motor sin avería mayor	<ul style="list-style-type: none"> Motor Sano Fallo Leve Fallo Medio 	Ninguna
	Avería mayor	Barra Rota	Mantenimiento

Figura 6.6 Diagnóstico del motor en función de su importancia.

Por ejemplo, en aviación se utiliza el término “Motor Crítico” al referirse a cualquier motor de la aeronave que al fallar imposibilitaría que el mismo continuase volando. En un caso menos extremista, en la fábrica también se puede catalogar a ciertos motores como de “Alta Importancia” si al fallar repentinamente, la producción se viese interrumpida por un periodo considerable de tiempo, con su correspondiente gran pérdida económica. En estos casos, el encargado de mantenimiento podría estar interesado sólo en saber si el motor está sano, sin mostrar signos de fallo, aunque sea leve. Pues al menor signo de fallo, ya se programaría la reparación o mantenimiento del motor tan pronto como sea posible, sin entorpecer la producción. Resumiendo, este trabajo está totalmente orientado al mantenimiento predictivo, basado en la observación

Capítulo 6: Propuesta de metodología de diagnóstico de barras rotas en Motores de Inducción orientada al mantenimiento

continua del estado de la máquina, pero con diferentes enfoques, en función de la criticidad o importancia del motor observado.

Por otro lado, si se consideran máquinas que tienen un rol secundario o de apoyo en la industria, el encargado podría optar por esperar a estar seguro de que el motor presente signos inequívocos de fallo moderado o grave antes de programar el mantenimiento del mismo. Es necesario recordar que en este trabajo se considera el diagnóstico de rotura de barras incipientes, por lo que un motor con el fallo más grave considerado, una barra totalmente rota, podría funcionar todavía algún tiempo antes de quedar inoperativo.

Con estas consideraciones, se propone optimizar los métodos de clasificación considerados para distinguir entre los siguientes casos, dejando al encargado de mantenimiento elegir cual utilizar:

- a) Se considera el caso general donde se pretende poder clasificar la medición del motor entre todas las clases o estados de fallo considerados. En esta tesis se denominada forma de clasificación F_{123} .
- b) Se considera un motor de “Muy Alta Importancia”, donde se optimiza el método de clasificación para separar solamente las mediciones de los motores sanos de los motores con fallos. Se denominará clasificación F_1 .
- c) Se considera que el motor tiene una importancia elevada, pero que aun así se puede admitir un fallo leve antes de enviar el mismo a mantenimiento, considerando el costo que el mantenimiento implica. Se denominará clasificación F_2 .
- d) El motor tiene una importancia baja y se puede admitir hasta fallos moderados en el mismo. Se espera hasta tener signos de una barra totalmente rota antes de programar el mantenimiento del mismo. Esta decisión puede aumentar el riesgo de fallo total, pero disminuiría el costo de mantenimiento. Se denominará clasificación F_3 .

La intención de optimizar de distinta forma los algoritmos de clasificación de acuerdo a la importancia del motor es la de dar al encargado de mantenimiento la opción de elegir cuál es la más conveniente en cada caso.

7 Ensayos.

7.1. Descripción de los ensayos.

En el presente capítulo se describen y analizan los ensayos realizados a los dos motores probados para el presente trabajo. Las características de ambos motores se describen en el anexo 1.

El esquema seguido para ensayar ambos motores se describe a continuación. Se realizaron mediciones de 10 segundos, con una frecuencia de muestreo de 80 kHz, con el motor sano primeramente con alimentación de red y luego con los variadores de frecuencia considerados: el Altivar 66 de Telemecánica para el Motor 1, el PowerFlex 40 de Allen-Bradley y el MicroMaster 420 de Siemens para el Motor 2. Con los variadores de frecuencia se realizaron ensayos con las siguientes frecuencias fundamentales de alimentación: 35Hz, 50 Hz y 65 Hz. Es decir, se decidió ensayar los motores a la misma frecuencia de red y a dos frecuencias diferentes más, una 15 Hz por debajo y otra 15 Hz por encima de la frecuencia de red, 50 Hz.

Posteriormente se desarmó el motor y se procedió a realizar una perforación en una barra del rotor de aproximadamente un tercio del espesor de la misma. Seguidamente se rearmó el motor y se procedió a ensayar el motor, con el considerado como Fallo Leve, con las alimentaciones de red y con los variadores a las frecuencias citadas anteriormente: 35 Hz, 50 Hz y 65 Hz.

En una tercera etapa del proceso de ensayo de los motores se desarmó nuevamente el motor y se procedió a continuar la perforación inicialmente realizada en la barra hasta dos tercios del espesor de la misma. Seguidamente se ensayó nuevamente el motor con las alimentaciones de red y variador consideradas.

Finalmente, se profundizó la perforación hasta traspasar totalmente la barra y se procedió a realizar un nuevo conjunto de ensayos con las mismas alimentaciones.

Las profundidades de las perforaciones hechas a los motores se muestran en la Tabla 7.1, y el número de ensayos realizados con cada tipo de alimentación en las Tablas 7.2 y 7.3.

Capítulo 7: Ensayos.

Tabla 7.1 Profundidad de las perforaciones a las barras de los motores 1 y 2.

	<u>Condición</u>	<u>Profundidad de la perforación</u>
Motor 1	Sano	0 mm
	Fallo Leve	6,48 mm
	Fallo Medio	11,7 mm
	Barra totalmente rota	17 mm
Motor 2	Sano	0 mm
	Fallo Leve	5,7 mm
	Fallo Medio	12,1 mm
	Barra totalmente rota	18 mm

Como puede verse en la Tabla 7.1 las perforaciones correspondientes a Fallo Leve son semejantes en ambos motores, lo mismo puede decirse de la profundidad de la perforación correspondiente al Fallo Medio. Esto se debe a que los motores no son muy diferentes entre sí y el espesor de barra de ambos difiere en apenas 1 milímetro.

Tabla 7.2 Números de ensayos realizados al Motor 1.

Red	Sano	83	
	Fallo Leve	26	
	Fallo Medio	21	
	Barra Rota	38	
Total Red		168	
Altivar 35 Hz	Sano	96	
	Fallo Leve	22	
	Fallo Medio	17	
	Barra Rota	21	
Total Altivar 35 Hz		156	
Altivar 50 Hz	Sano	100	
	Fallo Leve	23	
	Fallo Medio	22	
	Barra Rota	20	
Total Altivar 50 Hz		165	
Altivar 65 Hz	Sano	98	
	Fallo Leve	20	
	Fallo Medio	11	
	Barra Rota	18	
Total Altivar 65 Hz		147	
Total Motor 1		636	

En la Tabla 7.2 se describe la cantidad de ensayos realizados con el Motor 1. Se especifica también el número de ensayos realizados en cada condición del motor, es

Capítulo 7: Ensayos.

decir, la cantidad de ensayos hechos con el motor sano, con Fallo Leve, Fallo Medio o Barra Rota.

Tabla 7.3 Número de ensayos realizados al Motor 2.

Red	Sano	110	
	Fallo Leve	40	
	Fallo Medio	42	
	Barra Rota	47	
	Total Red		239
Allen-Bradley 35 Hz	Sano	138	
	Fallo Leve	42	
	Fallo Medio	40	
	Barra Rota	45	
	Total Allen-Bradley 35 Hz		265
Allen-Bradley 50 Hz	Sano	108	
	Fallo Leve	46	
	Fallo Medio	40	
	Barra Rota	46	
	Total Allen-Bradley 50 Hz		240
Allen-Bradley 65 Hz	Sano	107	
	Fallo Leve	41	
	Fallo Medio	49	
	Barra Rota	45	
	Total Allen-Bradley 65 Hz		242
Siemens 35 Hz	Sano	101	
	Fallo Leve	42	
	Fallo Medio	42	
	Barra Rota	45	
	Total Siemens 35 Hz		230
Siemens 50 Hz	Sano	99	
	Fallo Leve	43	
	Fallo Medio	42	
	Barra Rota	45	
	Total Siemens 50 Hz		229
Siemens 65 Hz	Sano	102	
	Fallo Leve	41	
	Fallo Medio	46	
	Barra Rota	45	
	Total Siemens 65 Hz		234
Total Motor 2		1679	

La Tabla 7.3 describe la cantidad de ensayos realizados al Motor 2. También se especifica la cantidad de ensayos realizados con cada tipo de alimentación y la condición del motor. Es importante indicar que los ensayos realizados al Motor 1

formaban parte de un banco de datos del departamento de Ingeniería Eléctrica de la Universidad de Valladolid al iniciar esta tesis, mientras que los ensayos del Motor 2 fueron realizados especialmente para este trabajo y forman parte de las aportaciones del mismo.

Cabe resaltar que entre ambos motores, considerando todas las alimentaciones estudiadas en el presente trabajo, se realizaron 2315 ensayos.

7.2. Descripción estadística de los ensayos obtenidos.

A continuación se describen y analizan los resultados obtenidos de los ensayos a los motores. En el análisis se indica la capacidad discriminante de las características, su dependencia con la carga y si esta relación es compleja o lineal. Debido a la gran cantidad de características consideradas como indicativas de fallo: 3 indicativas de la carga, 14 del espectro de la corriente y 15 estadísticos del dominio del tiempo de la señal, 32 en total, una explicación detallada de cada característica para cada tipo de alimentación resultaría extremadamente larga y no reportaría mayores beneficios. Considerando esto, se decidió mostrar solamente un par de las características más significativas para cada motor y tipo de alimentación a fin de dar una idea general de los mismos.

Para presentar los resultados de una forma simple y didáctica se muestra una gráfica de cajas separando los estados de fallo del motor y un gráfico de dispersión de la característica considerada como indicativa de la falta en función de otra variable indicativa de la carga del motor. Debido a que las tres características indicativas de la carga del motor, como es previsible, tienen una gran correlación entre sí, se utilizó el deslizamiento para el gráfico de dispersión. Se eligió el deslizamiento debido a que al ser un valor adimensional no es tan sensible a la frecuencia como la corriente o la velocidad del rotor.

7.2.1. Motor 1

a) Todos los ensayos

En la Fig. 7.1 se puede observar un diagrama de cajas y un diagrama de dispersión de todos los ensayos realizados al Motor 1 para la característica BI, la banda inferior al primer armónico obtenida de la transformada de Fourier.

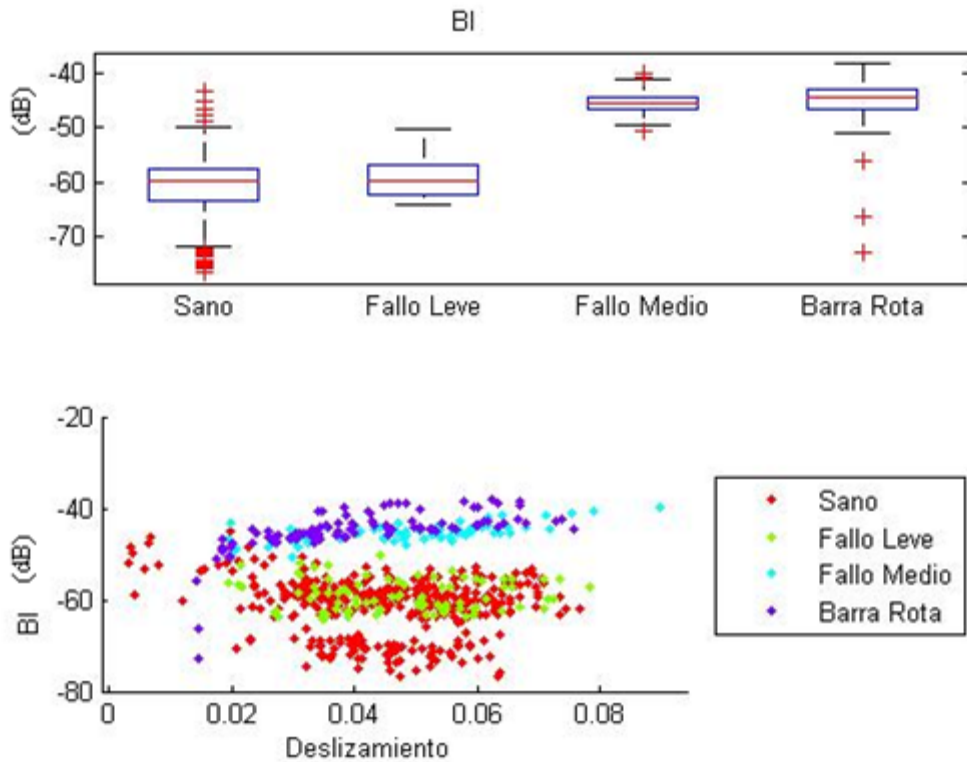


Figura 7.1. Todos los ensayos del Motor 1, característica: BI.

Analizando la Fig. 7.1 se puede apreciar que los ensayos correspondientes al motor Sano y al Fallo Leve se superponen bastante, siendo difícil separarlos. También los ensayos correspondientes a Fallo Medio y Barra Rota son difíciles de discriminar considerando la característica BI. Sin embargo, los ensayos del motor Sano o con Fallo Leve sí se pueden separar bastante bien de los ensayos con Fallo Medio o Barra Rota. Se puede observar que los ensayos con Fallo Leve o con Barra Rota aumentan proporcionalmente con el deslizamiento, aunque el aumento es muy poco significativo. En cambio, los ensayos de Motor Sano o con Fallo Leve no varían visiblemente con el aumento de la carga.

La Fig. 7.2 muestra el mismo resultado para la característica Momento 1, y se aprecia que con esta característica se pueden separar los ensayos con Fallo Medio del resto de ensayos. También los ensayos con Barra Rota pueden discriminarse de los demás con el Momento 1. Sin embargo, los ensayos con Fallo Leve y Motor Sano no son fácilmente separables.




Figura 7.2. Todos los ensayos del Motor 1, característica: Momento 1.

Las características elegidas, dependiendo del tipo de alimentación, no siempre proveen información útil para el diagnóstico. Por ejemplo, en la Fig. 7.3 se puede apreciar que la Curtosis no parece ser relevante para la clasificación, al menos considerando simultáneamente todos los tipos de alimentación. Cabe resaltar que este es un estudio previo al proceso de reducción de características para observar las relaciones que puedan existir entre variables y comprobar si, a priori, algunas características presentan mayor poder discriminante que otras. Sin embargo, no podemos eliminar características en esta etapa porque observamos sólo dos dimensiones de un conjunto de mayor dimensionalidad. Por ejemplo, la Curtosis representada en la Fig. 7.3 no parece tener capacidad discriminante, sin embargo, no podemos concluir que la Curtosis no sea útil para la clasificación pues, en conjunto con otras características, sí podría ser relevante para el diagnóstico. Considerando esto, el análisis de este capítulo sirve principalmente para comprender la complejidad del problema comprobando las relaciones entre variables. Además, se analiza si bajo distintas fuentes de alimentación las características tienen el mismo comportamiento o si la fuente de alimentación, además de la carga del motor y el estado de fallo, incide en el valor de las variables.




Figura 7.3. Todos los ensayos del Motor 1, característica: Curtosis.

b) Ensayos con alimentación de red

Para describir los ensayos del Motor 1 alimentado con red se presentan las Figs. 7.4 a la 7.6. Como puede apreciarse en la Fig. 7.4, la primera banda superior al armónico principal, obtenido por la transformada de Hilbert, HS, puede separar fácilmente los ensayos con Fallo Medio o con Barra Rota de los demás.

En la Fig. 7.5 se muestra cómo la característica Cumulante 3 tiene un alto poder discriminante aun considerando todas las condiciones de fallo, es decir, puede separar casi perfectamente todos los ensayos en cada tipo de fallo considerado.

La Fig. 7.6 presenta al Momento de 3^{er} orden. Como se puede observar, esta característica no presenta poder discriminante visible. En este caso, los ensayos del Motor Sano tienen poca desviación con respecto al promedio. Los ensayos con Fallo, a pesar de tener promedios similares, tienen un rango de valores más amplios que los ensayos con motor sano, con desviaciones mayores. En todos los casos se aprecia que la característica no varía considerablemente con la carga del motor.

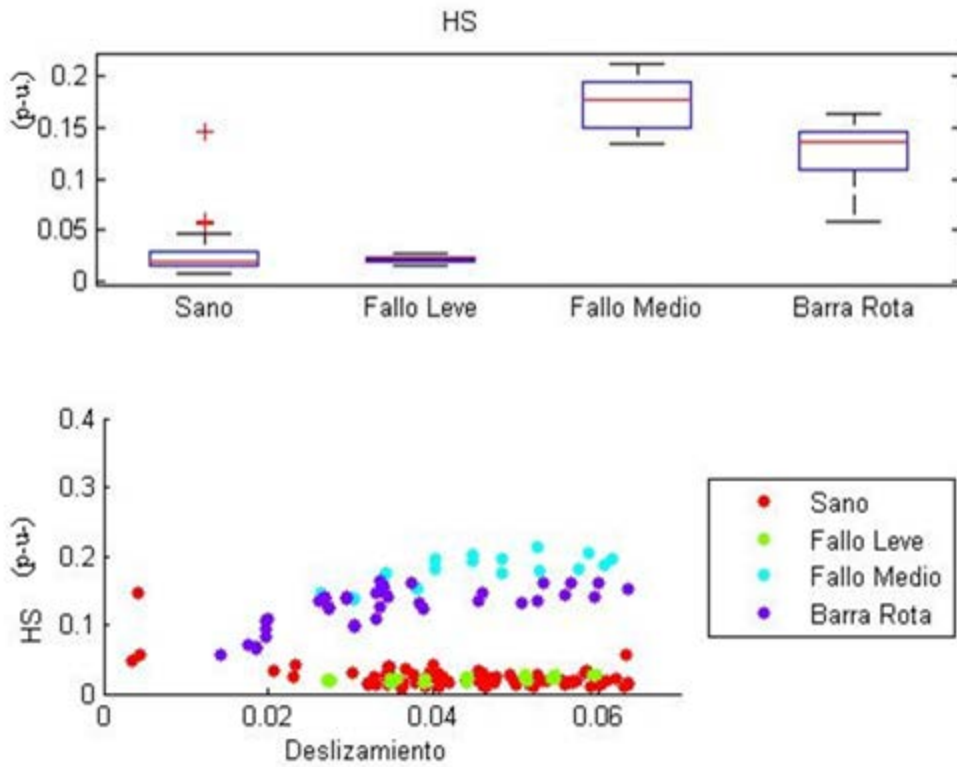


Figura 7.4. Ensayos con alimentación de Red del Motor 1, característica: HS.




Figura 7.5. Ensayos con alimentación de Red del Motor 1, característica: Cumulante 3.

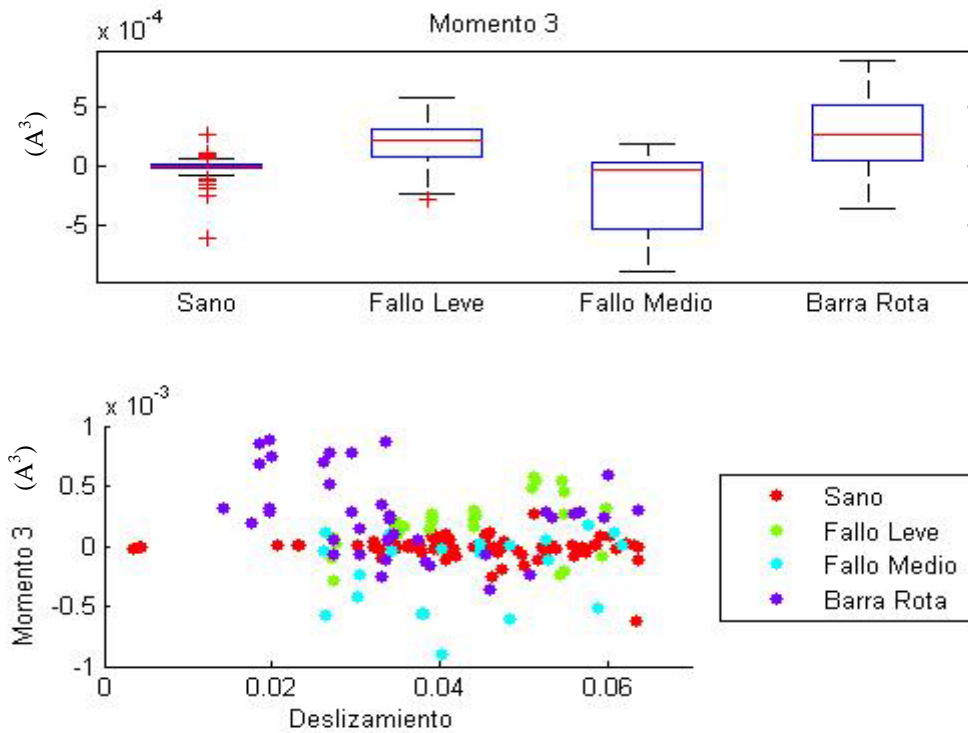


Figura 7.6. Ensayos con alimentación de Red del Motor 1, característica: Momento 3.

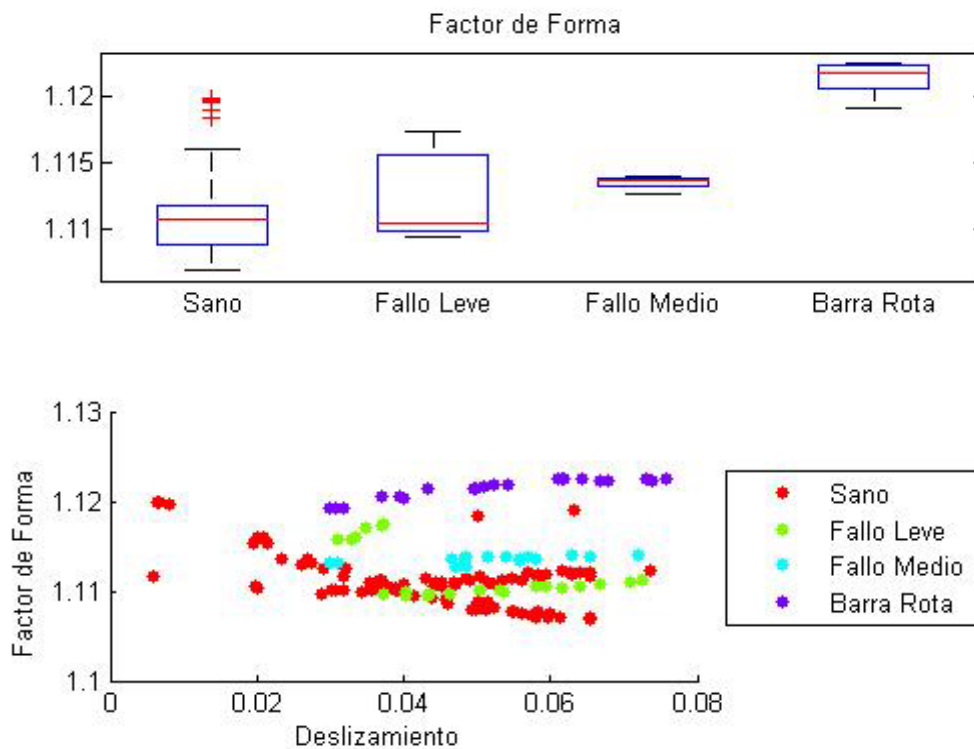


Figura 7.7. Ensayos con alimentación Altivar a 35 Hz, Motor 1, característica: Factor de Forma.

c) Ensayos con alimentación de variador Altivar a 35 Hz.

Las Figs. 7.7 a la 7.9 representan los ensayos del Motor 1 con alimentación de variador Altivar con una frecuencia de consigna de 35 Hz. La Fig. 7.7 muestra el Factor de

Forma. Esta característica permite separar los ensayos con Barra Rota de los demás ensayos, pues presentan un valor mayor que los otros estados de fallo. También se puede notar que en los ensayos con Motor Sano el valor del Factor de Forma decrece al aumentar el deslizamiento, mientras que en los ensayos con Barra Rota, la misma característica aumenta muy ligeramente con el deslizamiento.

En la Fig. 7.8 se puede notar que el Factor de Cresta sirve para separar los ensayos con Fallo Medio y con Fallo Leve de los demás. Es interesante notar que, para esta característica, los ensayos con Fallo Leve tienen un valor mayor que con Motor Sano, al considerar un Fallo Medio, es decir, un motor con una perforación de mayor profundidad, el Factor de Cresta aumenta con la gravedad del fallo. Sin embargo, al llegar al caso de Barra Rota, rotura total de la barra, el valor del Factor de Cresta disminuye hasta ser semejantes a los menores valores de los ensayos con Motor Sano. Es decir, la relación entre el Factor de Cresta y el estado de fallo no es lineal.




Figura 7.8. Ensayos con alimentación Altivar a 35 Hz, Motor 1, característica: Factor de Cresta.

La Fig. 7.9 muestra el Promedio de Valor Absoluto. Observando la gráfica de cajas, se puede notar que el promedio de la característica aumenta con el estado de fallo, es decir, el promedio de los ensayos con Fallo Medio es mayor que el promedio de los ensayos

con Fallo Leve y éste es mayor que el de los ensayos con Motor Sano. Sin embargo, la gráfica de dispersión no muestra que esta característica tenga un poder discriminante significativo. Se observa que esta característica aumenta proporcionalmente con el deslizamiento.




Figura 7.9. Ensayos con alimentación Altivar a 35 Hz, Motor 1, característica: Promedio de Valor Absoluto.

d) Ensayos con alimentación de variador Altivar a 50 Hz.

En esta sección se presentan los ensayos obtenidos con alimentación de variador Altivar a 50 Hz. Primeramente, en la Fig. 7.10, se muestra la característica Curtosis. Analizando esta figura se concluye que dicha característica puede separar perfectamente los ensayos con Fallo Medio del resto. También sirve para discriminar, salvo algunas excepciones a altos deslizamientos, entre los ensayos con Motor Sano y con Fallo Leve. Es interesante notar cómo la característica no es proporcional al estado de fallo, pues primero aumenta al producirse un Fallo Leve, luego disminuye considerablemente al llegar la perforación al Fallo Medio, para terminar subiendo nuevamente al producirse la rotura total de la barra. También se observa que esta variable disminuye al aumentar el deslizamiento, a excepción de los ensayos con Fallo Medio que a partir de un deslizamiento del 3% tienen un valor casi constante.

Capítulo 7: Ensayos.

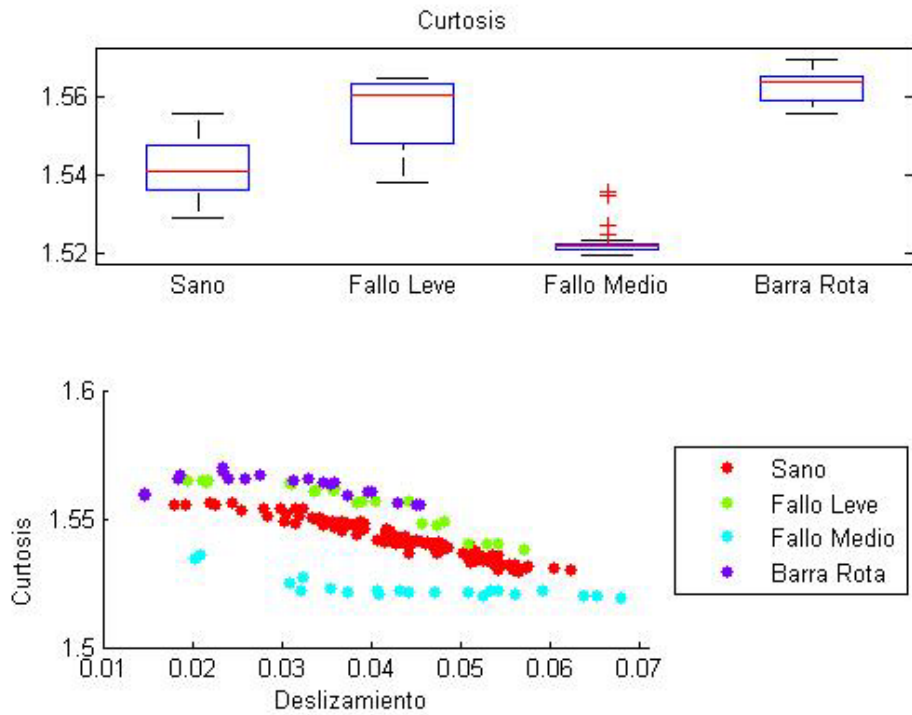



Figura 7.10. Ensayos con alimentación Altivar a 50 Hz, Motor 1, característica: Curtosis.



7.11. Ensayos con alimentación Altivar a 50 Hz, Motor 1, característica: Factor de Cresta.




Figura 7.12. Ensayos con alimentación Altivar a 50 Hz, Motor 1, característica: Factor de Cresta.

La Fig. 7.11 presenta al Factor de Cresta. Esta característica también tiene un poder discriminante notorio para separar los ensayos con Motor Sano y Fallo Medio de los demás. Contrariamente a la Curtosis, en esta característica los ensayos con Fallo Medio son los que tienen un valor mayor al resto de ensayos. El Factor de Cresta presenta una relación inversamente proporcional al deslizamiento, se observa cómo disminuye al aumentar la carga del motor.

El Momento de 6^{to} orden, mostrado en la Fig. 7.12, presenta poder discriminante, aunque no una separabilidad perfecta, entre los ensayos con Fallo Leve y Barra Rota. Sin embargo, en esta característica los ensayos con Motor Sano y Fallo Medio se solapan en casi todo el espectro de deslizamiento considerado. Considerando esto, esta característica debería ser seleccionada por el Análisis Discriminante como variable relevante para la clasificación. Esta característica también disminuye al aumentar el deslizamiento, aunque se aprecia una relación no lineal.

e) Ensayos con alimentación de variador Altivar a 65 Hz.

La Fig. 7.13 muestra cómo el Momento 1 separa perfectamente los ensayos del Motor 1 con alimentación de variador Altivar con frecuencia de consigna a 65 Hz. Se puede

notar que con esta característica no solo se puede separar perfectamente los estados de fallo del motor sino que, además, el valor de la misma es casi invariante con el deslizamiento y parece depender sólo del estado de fallo.

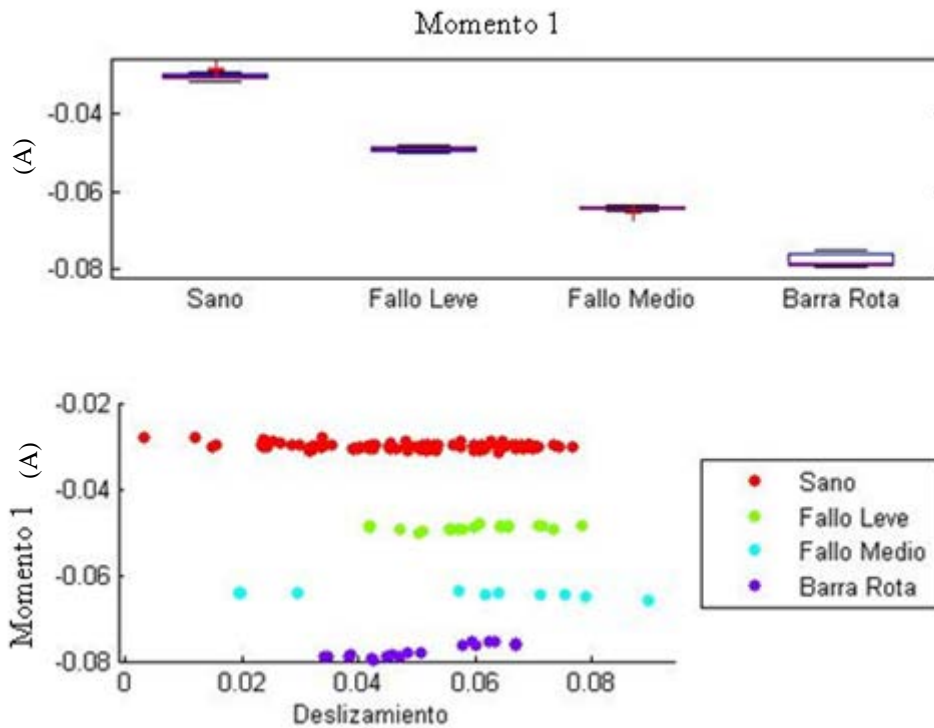


Figura 7.13. Ensayos con alimentación Altivar a 65 Hz, Motor 1, característica: Momento 1.




Figura 7.14. Ensayos con alimentación Altivar a 65 Hz, Motor 1, característica: BS.




Figura 7.15. Ensayos con alimentación Altivar a 65 Hz, Motor 1, característica: Factor de Cresta.

En la Fig. 7.14 se aprecia la característica BS, la primera banda superior al 1^{er} armónico obtenido con la Transformada de Fourier. En este caso, los ensayos con Fallo Medio y Barra Rota se pueden separar fácilmente entre sí y de los demás. Sin embargo, los ensayos con Fallo Leve no pueden ser discriminados de los ensayos con Motor Sano. También se observa que los ensayos con Fallo Medio o Barra Rota aumentan suavemente con la carga mientras que los ensayos de Motor Sano o con Fallo Leve no presentan una variación significativa con el deslizamiento.

La Fig. 7.15 presenta el Factor de Cresta para los ensayos con alimentación de variador Altivar a 65 Hz. Comparando esta gráfica con la Fig. 7.11 se puede notar cómo, al variar la frecuencia de alimentación, esta característica, que presenta un poder discriminante bueno a cuando la alimentación es a 50 Hz (ver Fig. 7.11), parece tener una capacidad de discriminación entre estados de fallo bastante pobre a los 65 Hz (Fig. 7.15) aún tratándose del mismo motor y variador. En ambos casos se observa que el valor del Factor de Cresta disminuye al aumentar la carga del motor.

7.2.2. Motor 2

A continuación se presenta un resumen de las características de los ensayos realizados al Motor 2, por la gran cantidad de características elegidas para este trabajo y considerando además el número de alimentaciones diferentes utilizadas para los ensayos, se muestran tres características por tipo de alimentación. Siguiendo el esquema utilizado para el Motor 1, primeramente se describen dos características con un poder discriminante evidente por su representación gráfica, y luego una tercera característica que no parece poseer una capacidad para separar los ensayos según su estado de fallo. Se eligió esta forma de resumir las características para mostrar que, según el tipo de alimentación, algunas características son más útiles que otras y que algunas tienen un alto poder discriminante con un determinado tipo de alimentación, pero la misma característica con otro tipo de alimentación puede no ser de mucha utilidad para el diagnóstico.

a) Todos los ensayos.

Las Figs. 7.16 y 7.17 presentan las características BI y B5I, las bandas inferiores al primer y quinto armónico obtenidos por la Transformada de Fourier. En ambas puede verse que, a partir de un deslizamiento medio, igual o mayor al 3%, estas características pueden discriminar entre un ensayo con Motor Sano o Fallo Leve y un ensayo con Fallo Medio o Barra Rota. Sin embargo, a bajos deslizamientos este poder discriminante es muy bajo o no es perceptible. También se observa que el valor de ambas características aumenta con el deslizamiento para los ensayos con Fallo Medio o Barra Rota, mientras que para los ensayos de Motor Sano o con Fallo Leve, el deslizamiento no parece incidir significativamente en el valor de las características.

En la Fig. 7.18 se pueden apreciar los valores de Skewness para todos los ensayos del Motor 2. Analizando dicha figura se concluye que esta característica no parece ser útil para el diagnóstico, al menos considerando todos los ensayos. También se aprecia una relación no lineal entre el deslizamiento y el Skewness.

Capítulo 7: Ensayos.




Figura 7.16. Todos los ensayos del Motor 2, característica: BI.

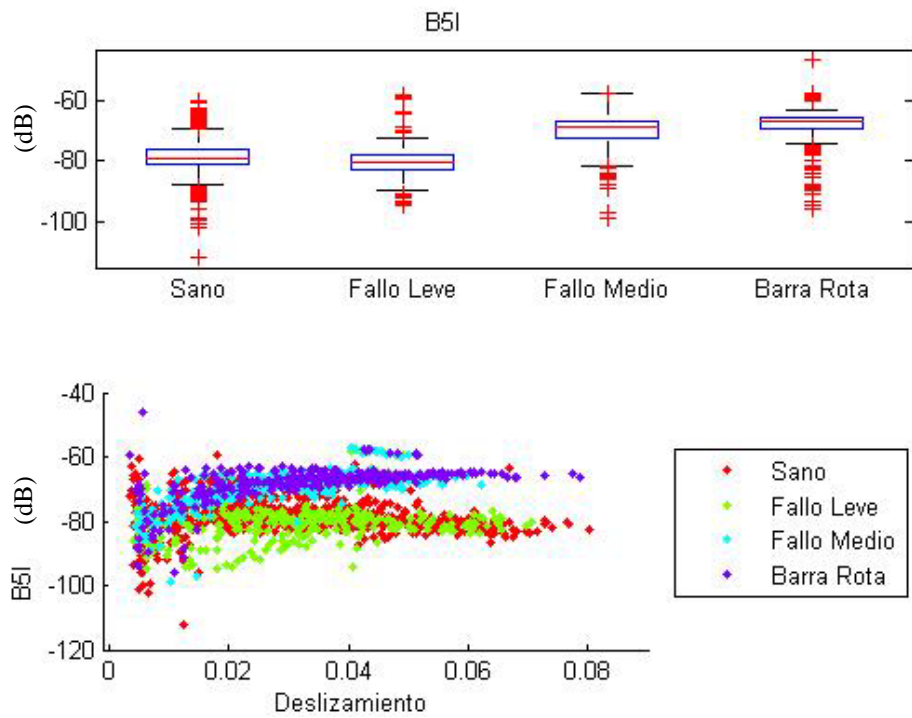


Figura 7.17. Todos los ensayos del Motor 2, característica: B5I.

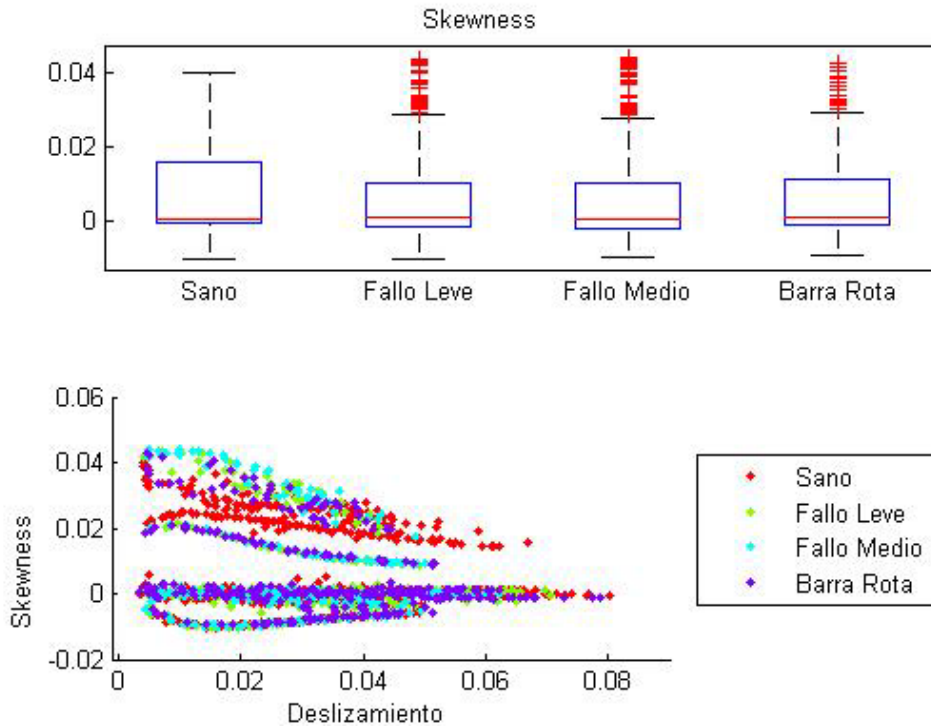


Figura 7.18. Todos los ensayos del Motor 2, característica: Skewness.

b) Ensayos con alimentación de red

Como se podrá constatar en el capítulo 8, los ensayos del Motor 2 alimentado con red están entre los más difíciles de clasificar. Debido a esto no se encontró ninguna característica que tenga por sí sola un alto poder discriminante, como por ejemplo el Cumulante 3 en los ensayos del Motor 1 alimentado con red (ver Fig. 7.5). Sin embargo, la Fig. 7.19 muestra cómo la característica HS, banda superior al 1^{er} armónico obtenido por transformada de Hilbert, puede separar los ensayos con Fallo Medio o Barra Rota de los ensayos con Motor Sano o Fallo Leve, pero sólo a deslizamientos altos.

La Fig. 7.20 presenta la Curtosis. Esta característica puede separar los ensayos con Fallo Leve del resto, excepto en el caso de muy bajo deslizamiento. En la Fig. 7.21 se muestra cómo el Skewness parece no depender del estado del fallo del motor para este tipo de alimentación.

En la Fig. 7.19 se observa como el valor de HS aumenta con el deslizamiento para los ensayos Fallo Medio o Barra Rota, mientras que la característica parece invariante con respecto a la carga del motor para los ensayos de Motor Sano o Fallo Leve. La relación

entre la Curtosis y el deslizamiento se presenta no lineal y el Skewness no presenta una dependencia significativa de la carga del motor

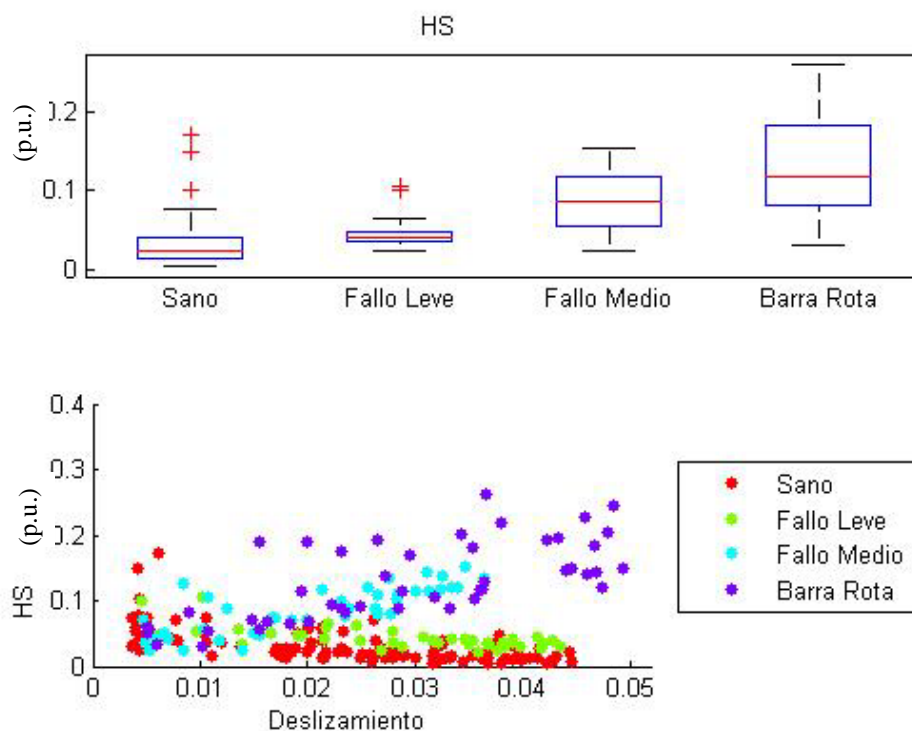


Figura 7.19. Ensayos con alimentación de Red del Motor 2, característica: HS.

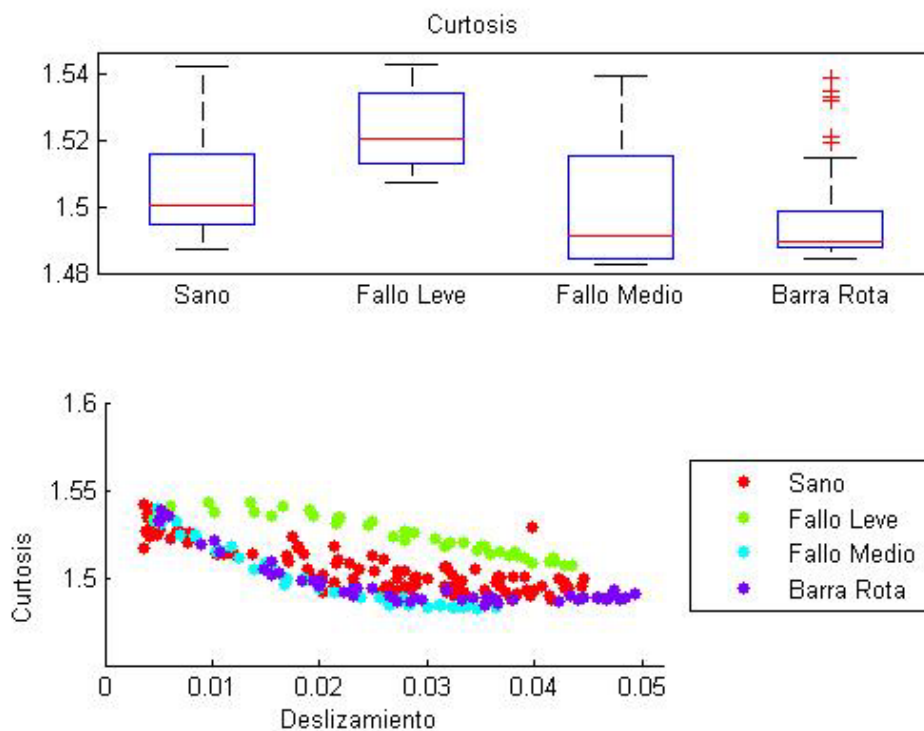


Figura 7.20. Ensayos con alimentación de Red del Motor 2, característica: Curtosis.

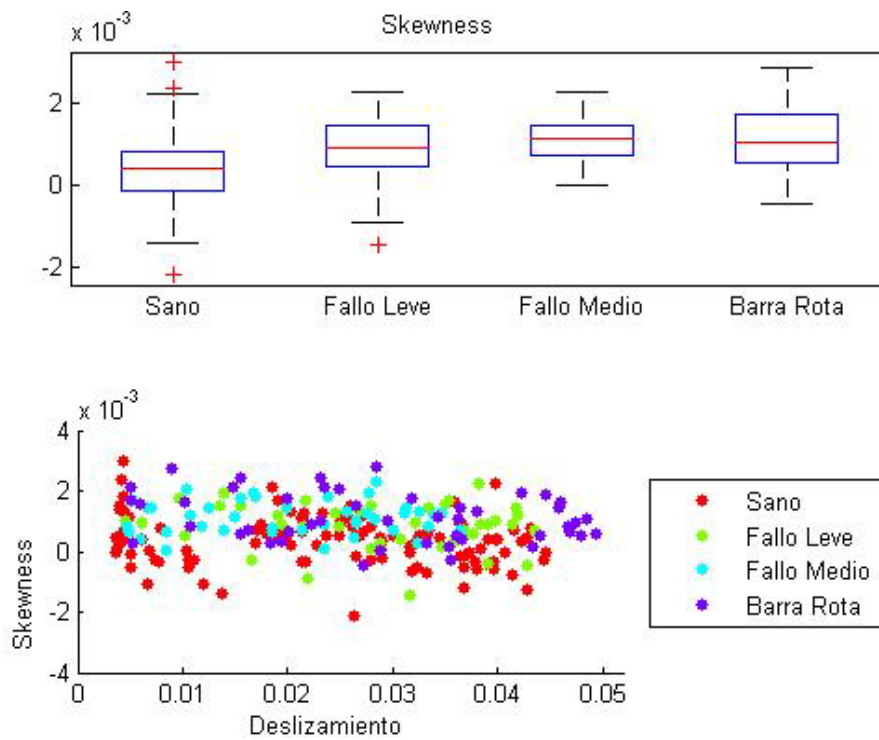


Figura 7.21. Ensayos con alimentación de Red del Motor 2, característica: Skewness.

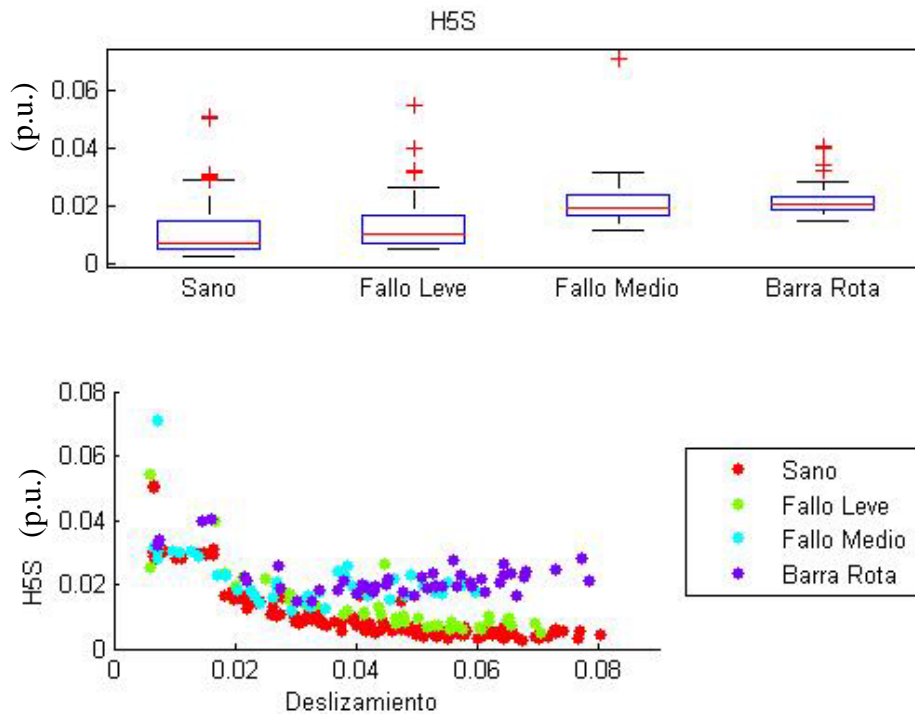


Figura 7.22. Ensayos con variador Allen-Bradley a 35 Hz del Motor 2, característica: H5S.

c) Ensayos con alimentación de variador Allen-Bradley a 35 Hz.

Considerando los ensayos realizados al Motor 2 con alimentación de variador Allen Bradley a 35 Hz, en la Fig. 7.22 se aprecia que la característica H5S, banda lateral

superior al 5^{to} armónico calculada con la Transformada de Hilbert, puede discriminar entre un ensayo de Motor Sano o con Fallo Leve de uno con Fallo Medio o Barra Rota, al menos para deslizamientos medios o altos.

La Fig. 7.23 muestra como el Factor de Forma puede separar los ensayos con Barra Rota o Fallo Leve de los ensayos de Motor Sano o Fallo Medio. Es interesante notar como el valor del Factor de Forma, para un deslizamiento determinado un poco superior al mínimo, aumenta visiblemente con un Fallo Leve, luego disminuye al aumentar el orificio para tener un Fallo Medio y vuelve a aumentar al ensayar el motor con una barra totalmente rota. En la Fig. 7.24 se observa como el Factor de Cresta disminuye de valor al aumentar el deslizamiento hasta un deslizamiento de aproximadamente el 3 %, para luego permanecer estable. Sin embargo, el valor de esta característica parece depender sólo del deslizamiento y tiene casi el mismo comportamiento para los cuatro estados de fallo considerados, por lo que en principio no tendría mucho valor como variable indicativa de fallo, al menos con este tipo de alimentación.

Las tres características presentan una relación no lineal compleja con la carga del motor, y esto probamente represente una dificultad para los algoritmos de clasificación.

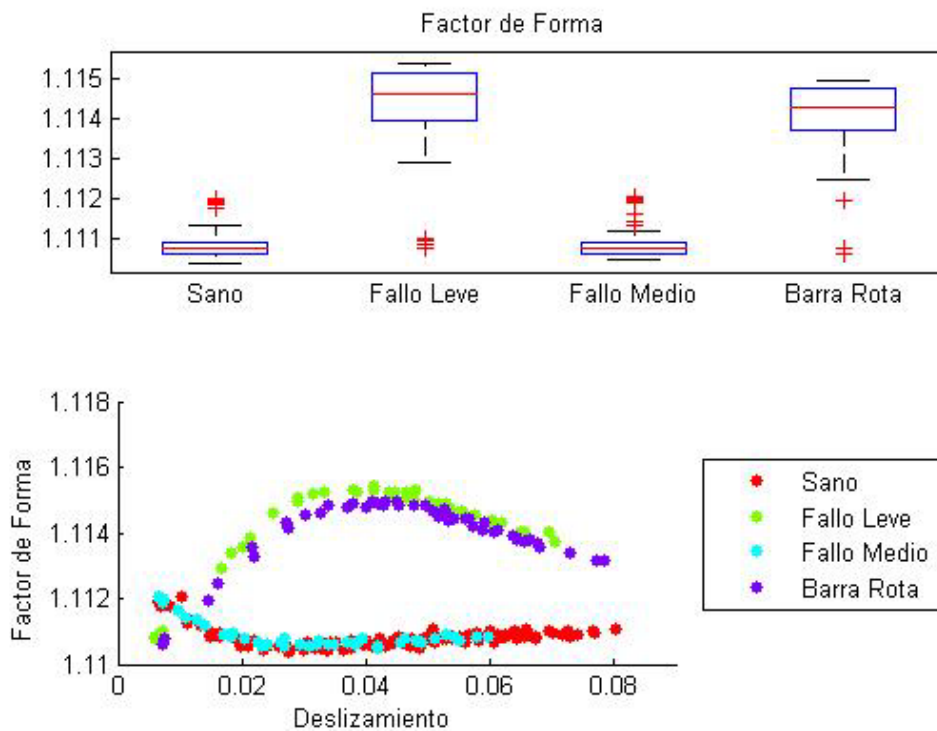


Figura 7.23. Ensayos con variador Allen-Bradley a 35 Hz del Motor 2, característica: Factor de Forma.

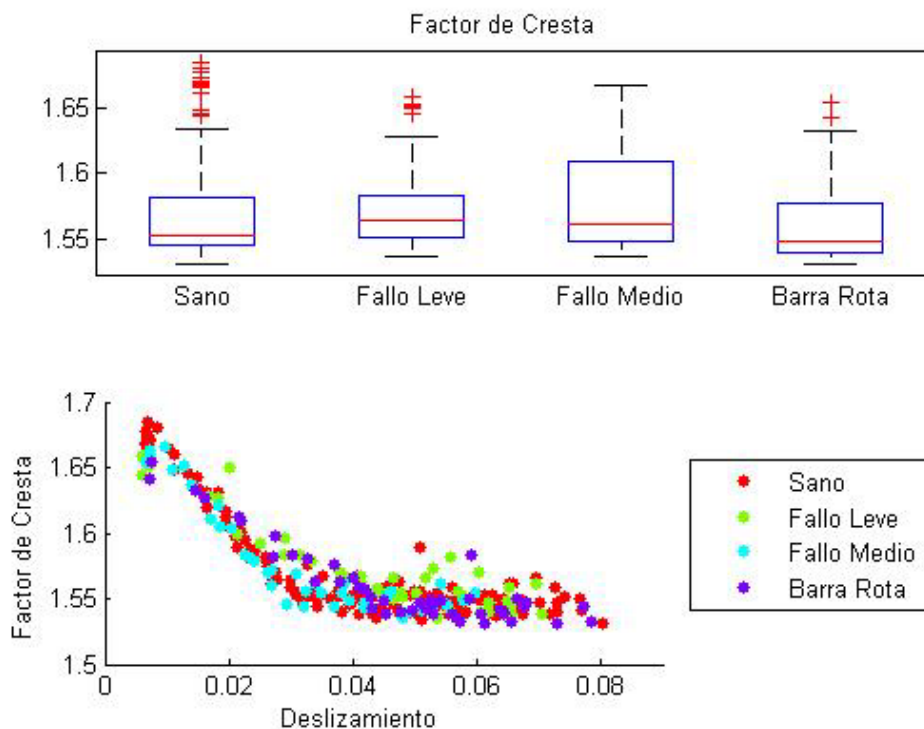


Figura 7.24. Ensayos con variador Allen-Bradley a 35 Hz del Motor 2, característica: Factor de Cresta.

d) Ensayos con alimentación de variador Allen-Bradley a 50 Hz.

Al analizar las características obtenidas con el Motor 2 alimentado con el variador Allen Bradley con una frecuencia de consigna de 50 Hz, notamos que la característica BS, banda superior al 1er armónico obtenido con la Transformada de Fourier, puede discriminar bastante bien entre un ensayo con Motor Sano o Fallo Leve de un ensayo con Fallo Medio o Barra Rota, como puede observarse en la Fig. 7.25.

La Fig. 7.26 presenta la característica B5I, es decir, la banda inferior al 5^{to} armónico obtenida con la Transformada de Fourier. En la misma se observa que la B5I puede servir para separar los ensayos de un Motor Sano o con Fallo Leve de uno con Fallo Medio o Barra Rota. Esta misma cualidad se observó con la B5I considerando todos los ensayos del Motor 2, sin embargo en ese caso el poder discriminante es algo menor (comparar con la Fig. 7.17).

La Fig. 7.27 muestra al Factor de Forma. En dicha figura se aprecia cómo, salvo algunas pocas excepciones, el valor del Factor de Forma no varía ni con el deslizamiento ni con el estado de fallo del motor.




Figura 7.25. Ensayos con variador Allen-Bradley a 50 Hz del Motor 2, característica: BS.




Figura 7.26. Ensayos con variador Allen-Bradley a 50 Hz del Motor 2, característica: B5I.




Figura 7.27. Ensayos con variador Allen-Bradley a 50 Hz del Motor 2, característica: Factor de Forma.

e) Ensayos con alimentación de variador Allen-Bradley a 65 Hz.

En la Fig. 7.28 se observa la característica B7I, la banda inferior al 7^{mo} armónico obtenida con la Transformada de Fourier, para los ensayos hechos al Motor 2 con alimentación del variador Allen Bradley a 65 Hz. En la misma se puede apreciar cómo los ensayos pueden ser fácilmente separados en tres grupos por esta característica. Primero los ensayos con Barra Rota, luego los ensayos con Fallo Leve y en un tercer grupo los ensayos con Motor Sano mezclados con los ensayos con Fallo Medio.

La Fig. 7.29 presenta la característica HS, banda superior al armónico principal obtenido con la Transformada de Hilbert. En esta gráfica se observa que la HS puede separar los ensayos con Motor Sano o Fallo Leve de los ensayos con Fallo Medio o Barra Rota. En la Fig. 7.30 se muestra la característica Skewness. Esta característica, a pesar de variar notablemente con respecto al deslizamiento, no parece responder de forma significativamente diferente a los estados de fallo del motor. Es de resaltar que la Skewness no variaba con el deslizamiento cuando se consideraba la alimentación con red del mismo motor (comparar Fig. 7.21 y 7.30). Para las características HS y Skewness se aprecia una relación compleja de las mismas con el deslizamiento. Como ya se indicó, esto puede representar una dificultad para realizar un diagnóstico correcto.

Capítulo 7: Ensayos.

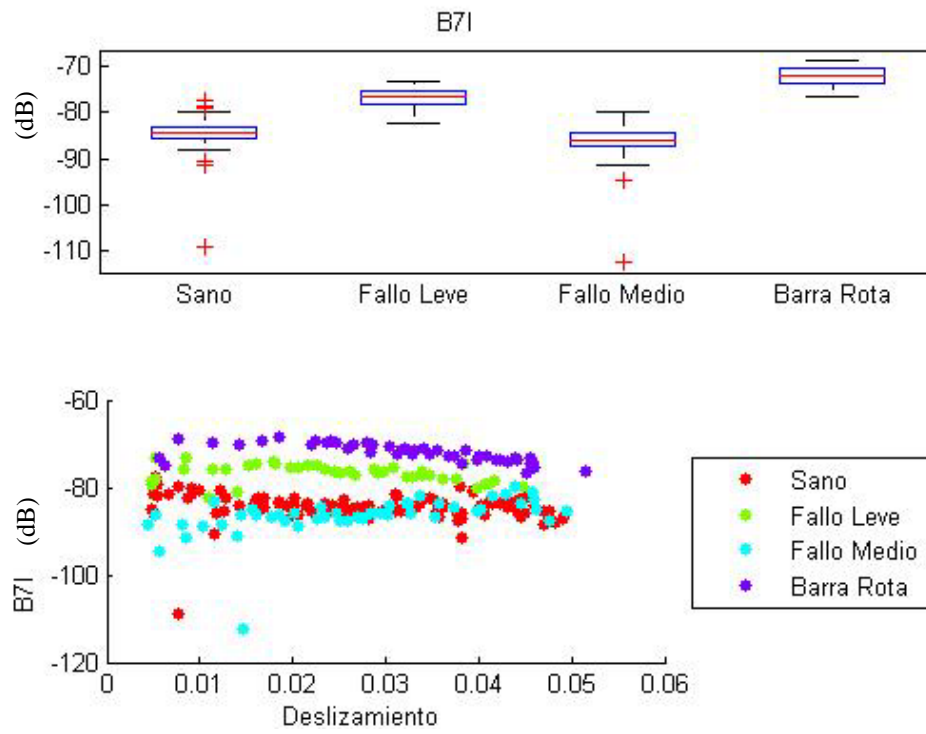


Figura 7.28. Ensayos con variador Allen-Bradley a 65 Hz del Motor 2, característica: B71.

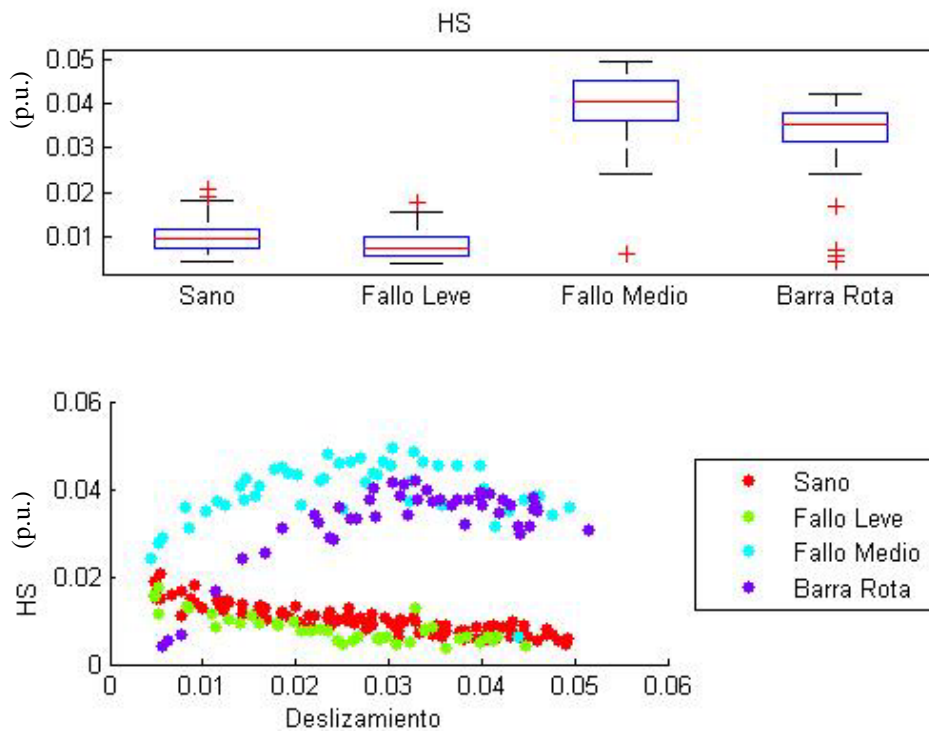


Figura 7.29. Ensayos con variador Allen-Bradley a 65 Hz del Motor 2, característica: HS.

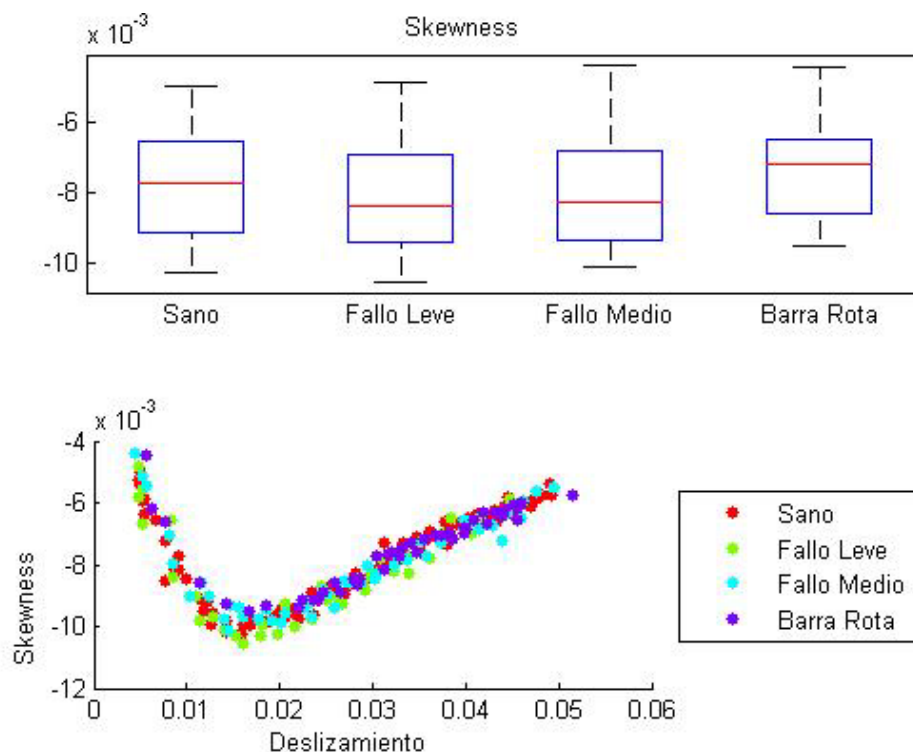


Figura 7.30. Ensayos con variador Allen-Bradley a 65 Hz del Motor 2, característica: Skewness.

f) Ensayos con alimentación de variador Siemens a 35 Hz.

Los ensayos obtenidos con el Motor 2 alimentado con el variador Siemens con una frecuencia de consigna de 35 Hz se muestran en las siguientes Fig. 7.31 a 7.33. En la Fig. 7.31 se observa cómo el Factor de Forma puede separar los ensayos en dos grupos, por un lado los ensayos con Fallo Leve o Fallo Medio y por otro los ensayos con Motor Sano y Barra Rota. Es conveniente recordar que la misma característica considerando los ensayos realizados al mismo motor pero con el variador Allen Bradley también a 35 Hz puede discriminar los ensayos de forma diferente. Al ver la Fig. 7.23 se observa que el Factor de Forma separa los ensayos entre los grupos Fallo Leve y Barra Rota o Motor Sano y Fallo Medio para el variador Allen Bradley a 35 Hz. Es decir, aún siendo el mismo motor y frecuencia, la característica varía de forma distinta con cada variador de frecuencia. En la Fig. 7.32 se observa como la característica BI puede separar los ensayos entre Motor Sano o con Fallo Leve y motor con Fallo Medio o Barra Rota. En la Fig. 7.33 se muestra cómo el Factor de Cresta varía de forma apreciable con el deslizamiento pero el estado de fallo parece no incidir en la variación de dicha característica. Este comportamiento es similar al obtenido con los ensayos con variador Allen Bradley a 35 Hz. En este caso también se aprecian relaciones complejas entre las características estadísticas Factor de Forma y Factor de Cresta con el deslizamiento.

Capítulo 7: Ensayos.

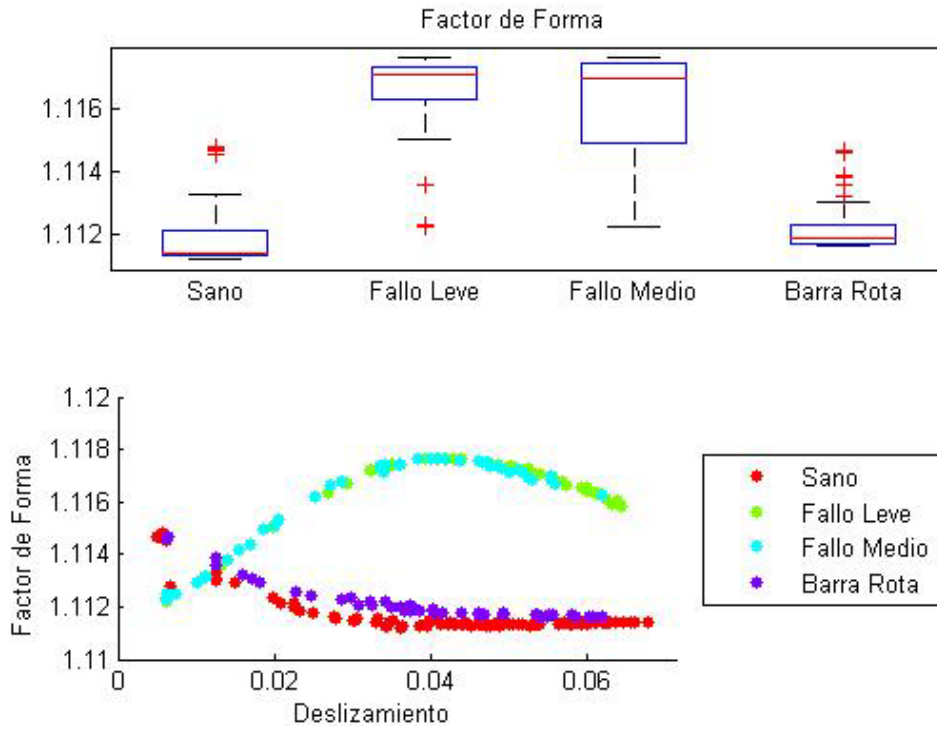


Figura 7.31. Ensayos con variador Siemens a 35 Hz del Motor 2, característica: Factor de Forma.

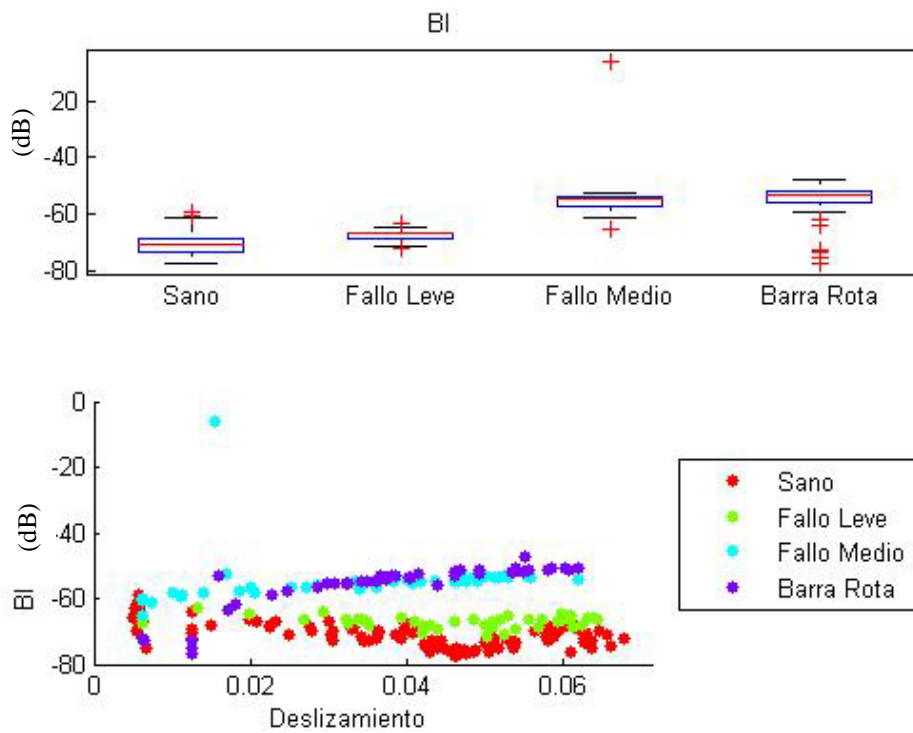


Figura 7.32. Ensayos con variador Siemens a 35 Hz del Motor 2, característica: BI.




Figura 7.33. Ensayos con variador Siemens a 35 Hz del Motor 2, característica: Factor de Cresta.

g) Ensayos con alimentación de variador Siemens a 50 Hz.

Las siguientes figuras muestran 3 de las características para los ensayos realizados al Motor 2 con el variador Siemens con una frecuencia de consigna de 50 Hz.

En las Fig. 7.34 y 7.35 se observa cómo las características BI y HS pueden discriminar, a partir de un deslizamiento medio, entre los ensayos con Fallo Medio o Barra Rota de los ensayos con Motor Sano o Fallo Leve.

La Fig. 7.36 presenta el Factor de Forma. A primera vista parece no tener poder discriminante, esto es debido a que los valores obtenidos en los ensayos con Motor Sano parecen variar en un rango más amplio que los otros ensayos. Sin embargo, si obviamos los ensayos con Motor Sano, se observa que los ensayos con Barra Rota sí se pueden discriminar de los ensayos con Fallo Medio o Leve. Recordando la Fig. 7.27, notamos que esta variable no parece tener ningún poder de discriminación con los ensayos obtenidos con el variador Allen Bradley a la misma frecuencia de 50 Hz.

Capítulo 7: Ensayos.




Figura 7.34. Ensayos con variador Siemens a 50 Hz del Motor 2, característica: BI.




Figura 7.35. Ensayos con variador Siemens a 50 Hz del Motor 2, característica: HS.




Figura 7.36. Ensayos con variador Siemens a 50 Hz del Motor 2, característica: Factor de Forma.

h) Ensayos con alimentación de variador Siemens a 65 Hz.

Finalmente, las tres últimas figuras presentan las características para los ensayos realizados al Motor 2 con variador Siemens a 65 Hz.

En la Fig. 7.37 se observa cómo la característica HS puede separar perfectamente, excepto en los ensayos en vacío, los ensayos con Barra Rota de los demás.

La Fig. 7.38 muestra la Skewness, la cual puede separar claramente a los ensayos con Motor Sano del resto de ensayos a todos los deslizamientos ensayados. Nótese como la Skewness no tenía poder discriminante en los ensayos realizados al Motor 2 con variador Allen Bradley también a 65 Hz (ver Fig. 7.30).

Analizando la Fig. 7.39 se puede observar que la característica B7I, banda inferior alrededor del 7^{mo} armónico obtenido con la Transformada de Fourier, no presenta capacidad visible para separar los ensayos realizados con el variador Siemens. Sin embargo, recordando la Fig. 7.28, esta misma característica sí puede separar los ensayos con Fallo Leve y Barra Rota de los demás cuando se considera la alimentación con variador Allen Bradley, a la misma frecuencia de 65 Hz.




Figura 7.37. Ensayos con variador Siemens a 65 Hz del Motor 2, característica: HS.

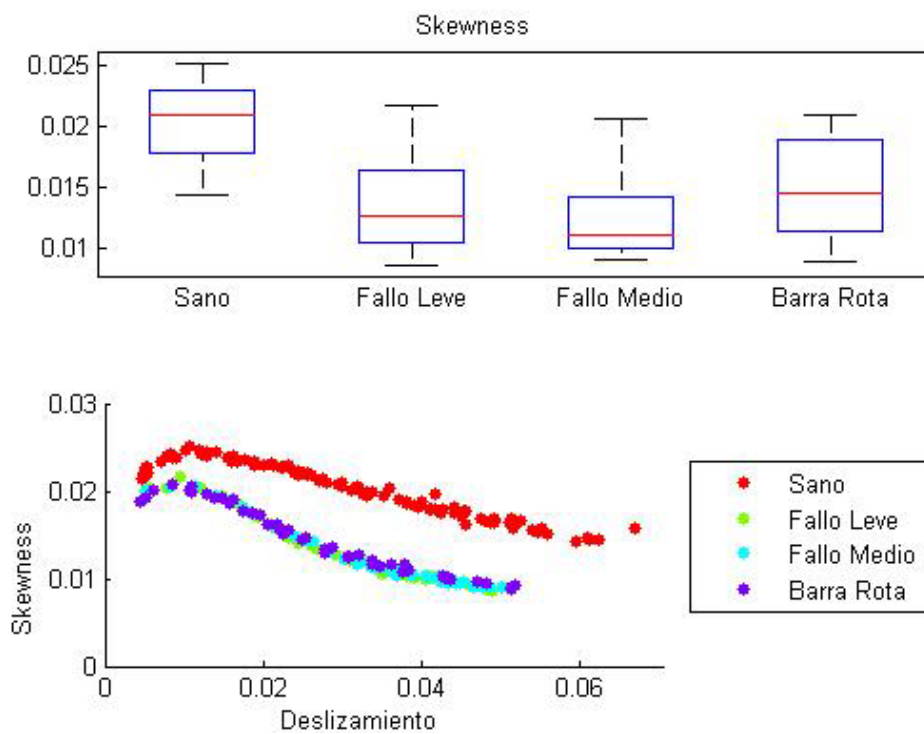


Figura 7.38. Ensayos con variador Siemens a 65 Hz del Motor 2, característica: HS.

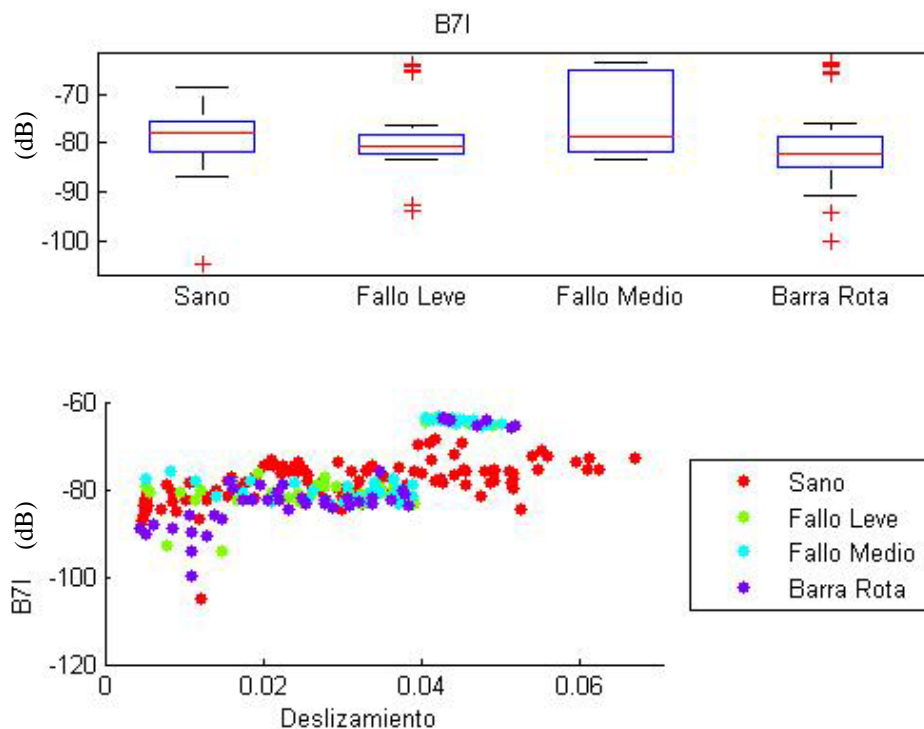


Figura 7.39. Ensayos con variador Siemens a 65 Hz del Motor 2, característica: Factor de Forma.

7.3 Conclusiones

En este capítulo se realizó un estudio preliminar de las características seleccionadas como indicativas de fallo. La finalidad de este estudio es obtener una estimación de la complejidad del problema y detectar relaciones entre las características con el nivel de carga del motor y con el estado de fallo. Algunas características presentaron un alto poder discriminante para separar los ensayos en los estados de fallo considerados. Por ejemplo, la Fig. 7.13 nos muestra cómo el Momento 1 puede discriminar perfectamente entre los 4 estados de fallos considerados para los ensayos obtenidos con el Motor 1 alimentado con el variador Altivar a 65 Hz. Se espera que esta variable, o una con una muy alta correlación con ésta, sea seleccionada por el Análisis Discriminante como característica relevante para la clasificación en este caso. Además, considerando el alto poder discriminante que presenta esta característica se presume que todos los algoritmos podrán realizar una clasificación correcta próxima al 100%.

No en todos los grupos de ensayos es posible encontrar una característica que tenga un poder discriminante tan grande. De hecho, en la mayoría de los casos ninguna característica puede discriminar por si sola entre los 4 estados de fallo considerados. Por esta razón se realiza el proceso de selección de variables que permite trabajar únicamente con las variables indicativas de fallo que tienen un poder discriminante alto.

Se han presentado características que tienen un alto poder discriminante, como el Momento 1 de la Fig. 7.13, que muy probablemente serán seleccionadas por el Análisis Discriminante como característica relevante para la clasificación. También se han presentado variables que en una inspección visual no demuestran tener capacidad discriminante alguna, como la Curtosis para el grupo de todos los ensayos obtenidos con el Motor 1. Sin embargo, no podemos afirmar que la Curtosis no sea relevante para la clasificación pues no podemos observar su relación con las demás variables. Es decir, la figura nos presenta solamente una representación bidimensional de un problema multidimensional, por lo que la Curtosis, combinada con otras características, sí podría ser relevante para la clasificación. Finalmente será el Análisis Discriminante implementado en el proceso de reducción de variables el que nos dará la información final sobre la relevancia de las variables para la clasificación.

Por otro lado, este análisis nos permite estimar la complejidad del problema de diagnóstico para los distintos casos. Como se observó en el análisis hecho a las características obtenidas con el Motor 1, no es difícil encontrar características que tengan un alto poder discriminante, como por ejemplo el Cumulante 3 para los ensayos alimentados con red, Fig. 7.5, o el Momento 1 de los ensayos obtenidos con variador a 65 Hz, Fig. 7.13. Considerando esto, se espera que el problema no presente grandes dificultades para los algoritmos y todos obtengan altos porcentajes de clasificación. Sin embargo, el análisis de las características del Motor 2 mostró capacidades discriminantes menores y relaciones más complejas entre las características y el deslizamiento. Por ejemplo, el Factor de Forma de los ensayos obtenidos con el variador Siemens a 35 Hz, Fig. 7.31, tiene un comportamiento muy diferente al Factor de Forma de los ensayos obtenidos con el variador Allen Bradley también a 35 Hz, Fig. 7.23. También podemos resaltar la relación no lineal entre el Skewness de los ensayos obtenidos con el variador Allen Bradley a 65 Hz, Fig. 7.30, sin embargo, la misma característica Skewness parece no depender en absoluto del deslizamiento cuando se consideran los ensayos obtenidos con alimentación de red para el mismo motor. Esto nos induce a pensar que probablemente los ensayos obtenidos con el Motor 2 sean más difíciles de clasificar que los obtenidos con el Motor 1. Además, considerando las relaciones no lineales de algunas características con los estados de fallo y el diferente comportamiento de una característica con diferentes alimentaciones, se espera que los grupos de ensayos que asocien a ensayos obtenidos a diferentes frecuencias o con

Capítulo 7: Ensayos.

diferentes alimentadores sean más difíciles de clasificar que aquellos que sólo consideren una fuente de alimentación. Por esto, posiblemente el grupo M2 sea el más difícil de clasificar correctamente.

Finalmente, si consideramos las cualidades de los algoritmos que se estudian, se presume que los métodos basados en Redes Neuronales sean superiores a los métodos estadísticos en los grupos de ensayos más complejos. Recordando que las Redes Neuronales pueden aproximar relaciones muy complejas mientras que el Análisis Discriminante solamente trabaja con relaciones lineales y la Regresión Logística, si bien puede admitir límites de clasificación con cierta curvatura, comete más errores al aumentar la complejidad del problema.

8 Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

8.1 Introducción

En el presente capítulo se presentan los resultados de la metodología propuesta para el diagnóstico incipiente de roturas de barras en motores de inducción.

Inicialmente se calcularon una gran cantidad de características de las señales, tanto en el dominio del tiempo como de la frecuencia. *A priori* se espera que estas variables indicativas de fallo aporten información sobre el estado de fallo del motor. Es necesario estudiar si se puede reducir el número de características para evitar sesgos por información duplicada, utilizar variables altamente correlacionadas que provocarían un coste computacional más elevado del requerido, entre otras razones.

La reducción de variables se realizó en dos etapas. Primeramente, se muestra la eliminación de variables indicativas de fallo fuertemente correlacionadas linealmente por medio de un análisis de correlación simple, utilizando el coeficiente de correlación de Pearson. A continuación, se seleccionan las características más relevantes para la clasificación mediante el Análisis Discriminante, utilizando la totalidad de los ensayos disponibles en cada caso. Con este proceso de dos etapas se reducen las variables para disminuir los vectores de entrada a los algoritmos de clasificación que se utilizarán. Así, se pretende conseguir disminuir el tiempo y esfuerzo de computación, tanto en calcular dichas características no esenciales como en la implementación de los algoritmos, manteniendo la eficiencia en el diagnóstico o clasificación de fallos.

Seguidamente, se implementaron los algoritmos clasificadores considerados, tanto con todas las variables indicativas de fallo originalmente, como con el conjunto reducido en la primera etapa. Esto se realizó para poder comprobar que, efectivamente, los algoritmos no pierden eficacia en la clasificación al utilizar menos características.

Al presentar los resultados de los clasificadores, primeramente se muestran los resultados de cada algoritmo por separado, del Análisis Discriminante como clasificador, de la Regresión Logística y de las Redes Neuronales, tanto en su versión simple como en Ensemble, para finalmente comparar la eficiencia de los algoritmos entre sí.

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

Debido a la variedad de tipos de alimentación que se utilizaron para obtener los ensayos, tres alimentadores distintos a tres frecuencias diferentes, además de la alimentación de red, se separaron los ensayos en varios grupos para su estudio. Para facilitar la interpretación de los resultados, la Tabla 8.1 describe las diferentes agrupaciones de los ensayos que se han efectuado para realizar los diferentes estudios de diagnóstico que se presentan en este capítulo. Se indica la nomenclatura que se utilizará en el resto de la presente tesis.

Tabla 8.1 Nomenclatura de los grupos de ensayos según el tipo de alimentación.

	<u>Nomenclatura</u>	<u>Descripción del grupo</u>
1	M1	Todos los ensayos obtenidos con el Motor M1
2	M1 50 Hz	Los ensayos obtenidos con el M1 a 50 Hz, incluyendo los ensayos con alimentación de red y con variador
3	Alt	Los ensayos obtenidos con el Motor 1 y el variador Altivar a 35 Hz, 50 Hz y 65 Hz
4	Alt 35Hz	Los ensayos obtenidos con el Motor 1 y el variador Altivar a 35 Hz
5	Alt 50Hz	Los ensayos obtenidos con el Motor 1 y el variador Altivar a 50 Hz
6	Alt 65Hz	Los ensayos obtenidos con el Motor 1 y el variador Altivar a 65 Hz
7	M1 Red	Los ensayos obtenidos con el Motor 1 y alimentación de red
8	M2	Todos los ensayos obtenidos con el Motor M2
9	M2 65Hz	Los ensayos obtenidos con el M2 a 65 Hz, incluyendo los ensayos con alimentación del variador Allen Bradley y Siemens
10	M2 50Hz	Los ensayos obtenidos con el M2 a 50 Hz, incluyendo los ensayos con alimentación del variador Allen Bradley, Siemens y red
11	M2 35Hz	Los ensayos obtenidos con el M2 a 35 Hz, incluyendo los ensayos con alimentación del variador Allen Bradley y Siemens
12	AB	Los ensayos obtenidos con el Motor 2 y el variador Allen-Bradley a 35 Hz, 50 Hz y 65 Hz
13	AB 35Hz	Los ensayos obtenidos con el Motor 2 y el variador Allen Bradley a 35 Hz
14	AB 50Hz	Los ensayos obtenidos con el Motor 2 y el variador Allen Bradley a 50 Hz
15	AB 65Hz	Los ensayos obtenidos con el Motor 2 y el variador Allen Bradley a 65 Hz
16	SM	Los ensayos obtenidos con el Motor 2 y el variador Siemens a 35 Hz, 50 Hz y 65 Hz
17	SM 35Hz	Los ensayos obtenidos con el Motor 2 y el variador Siemens a 35 Hz
18	SM 50Hz	Los ensayos obtenidos con el Motor 2 y el variador Siemens a 50 Hz
19	SM 65Hz	Los ensayos obtenidos con el Motor 2 y el variador Siemens a 65 Hz
20	M2 Red	Los ensayos obtenidos con el Motor 2 y alimentación de red

Como se muestra en la Tabla 8.1, se consideraron 20 grupos de ensayos diferentes de acuerdo al tipo de alimentación, 7 para el Motor 1 y 13 para el Motor 2.

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

Recordando la Sección 6.5, en este estudio se consideraron varias formas de clasificar los ensayos de acuerdo a la importancia que se asigna al motor. Así, se consideraron 4 formas de clasificar o diagnosticar los ensayos. En la primera, se clasifican los ensayos en 4 clases o estados de fallo: Sano, Fallo Leve, Fallo Medio y Barra Rota. Recordemos que a esta primera forma de diagnosticar en 4 clases se la denominó F_{123} . En la segunda forma de clasificación se considera que el motor es de muy alta importancia (importancia crítica), donde sólo se requiere detectar si el motor está sano o tiene algún tipo de fallo, sea este fallo leve o grave, por lo que se divide a los ensayos en 2 clases: motor sano o motor con fallo (que incluye a las clases Fallo Leve, Fallo Medio y Barra Rota). Esta segunda forma de clasificar se denomina F_1 . La tercera forma de clasificar, denominada F_2 , separa a los ensayos entre motores Sanos o con Fallo Leve por un lado, y motores con Fallo Medio o Barra Rota por otro lado. La última forma de clasificar considerada en esta tesis, F_3 , separa a los ensayos con Barra Rota de los demás ensayos. Esta forma de clasificación correspondería a un motor de baja importancia o fácilmente sustituible en caso de avería. Teniendo en cuenta los 20 grupos de ensayos (Tabla 8.1) de acuerdo al tipo de alimentación, y las 4 formas de clasificación de acuerdo a la importancia del motor, se consideran 80 casos para diagnosticar. Así, para designar un caso se cita el grupo de ensayos de acuerdo al tipo de alimentación y luego la forma de clasificación, por ejemplo, M2 F_{123} representa al caso que considera todos los ensayos realizados al Motor 2 y las cuatro clases de fallo.

Tabla 8.2 Definición de las formas de clasificación consideradas.

<u>Nomenclatura</u>	<u>Definición de la forma de clasificación</u>
F_{123}	Discrimina entre los cuatro estados de fallo considerados: Motor Sano, Fallo Leve, Fallo Medio y Barra Rota.
F_1	Discrimina solamente entre motor sano y motor con fallo, es decir, separa en: i) motor Sano, ii) motor con Fallo Leve, Fallo Medio o Barra Rota.
F_2	Discrimina entre motor sano o con Fallo Leve y motor con Fallo Medio o Barra Rota, es decir, separa en: i) Motor Sano o Fallo Leve, ii) Fallo Medio o Barra Rota.
F_3	Discrimina entre motor con Barra Rota y el resto, es decir, separa en: i) Motor Sano, Fallo Leve o Fallo Medio, ii) motor con Barra Rota.

Para poder hacer una mejor comparación entre los resultados se decidió repetir el esquema de validación cruzada de 10 iteraciones, 10 veces y promediar los resultados. Es decir, se separaron los ensayos de cada caso en 10 grupos, se implementó cada algoritmo 10 veces, utilizando cada vez un grupo de ensayos diferente como grupo de validación. Seguidamente se repitió el proceso 9 veces más, dividiendo de forma diferente los ensayos cada vez. Finalmente, cada ensayo fue utilizado 10 veces en el

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

grupo de validación y 90 veces como parte del grupo de entrenamiento de los algoritmos.

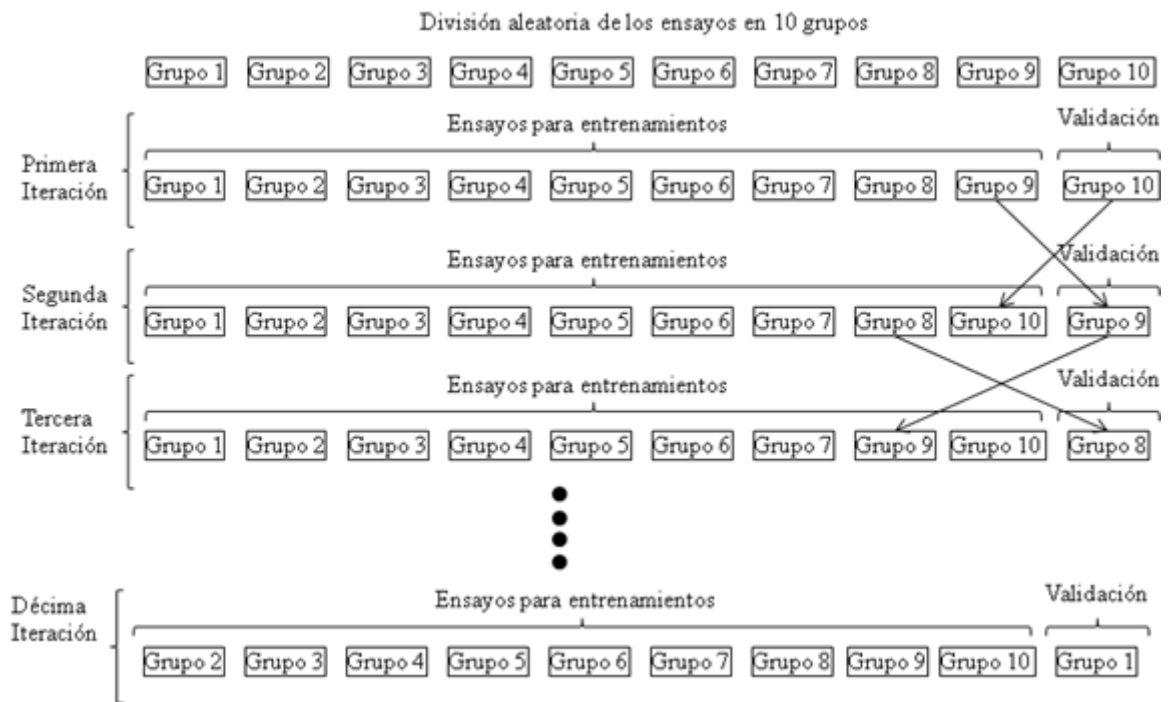


Figura 8.1 Método de validación cruzada 10-fold o de 10 iteraciones.

8.2 Reducción del número de características

El proceso de reducción del número de variables indicativas de fallo se realizó en un proceso de dos etapas. Primeramente se eliminaron las características muy correlacionadas linealmente entre sí, y luego se seleccionaron las variables más relevantes para la clasificación según el Análisis Discriminante. Este proceso se repitió para los 80 casos considerados en esta tesis. La Fig. 8.2 esquematiza este proceso en un diagrama de flujo.

Las tres características indicativas del nivel carga del motor representan un caso particular debido a que no son de por sí indicativas del estado fallo del motor. Evidentemente, un motor puede tener un Fallo Leve, Barra Rota o ser un Motor Sano independientemente de la carga del motor. Sin embargo, algunas características varían con el nivel de carga del motor, así, un valor determinado de una característica podría corresponder a un estado de fallo a bajos deslizamientos y ese mismo valor le correspondería a otro estado de fallo a deslizamientos mayores (ver Fig. 7.29, por

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

ejemplo). Por lo tanto, es conveniente que los algoritmos reciban al menos una de estas características como dato de entrada.

Cuando consideramos un grupo de ensayos obtenidos a la misma frecuencia, las tres características asociadas al nivel de carga del motor están altamente correlacionadas, debido a que, básicamente, representan lo mismo. Por esto se optó por conservar el deslizamiento como característica útil para la clasificación, como ya se ha mencionado anteriormente.

Sin embargo, cuando se asocian ensayos obtenidos a frecuencias diferentes, el deslizamiento ya no presenta una correlación alta con la velocidad o la corriente de otros ensayos realizados a diferente frecuencia. Considerando esto, para los 5 grupos que asocian ensayos a diferentes frecuencias se conservaron la velocidad y el deslizamiento como características a ser utilizadas por los algoritmos.

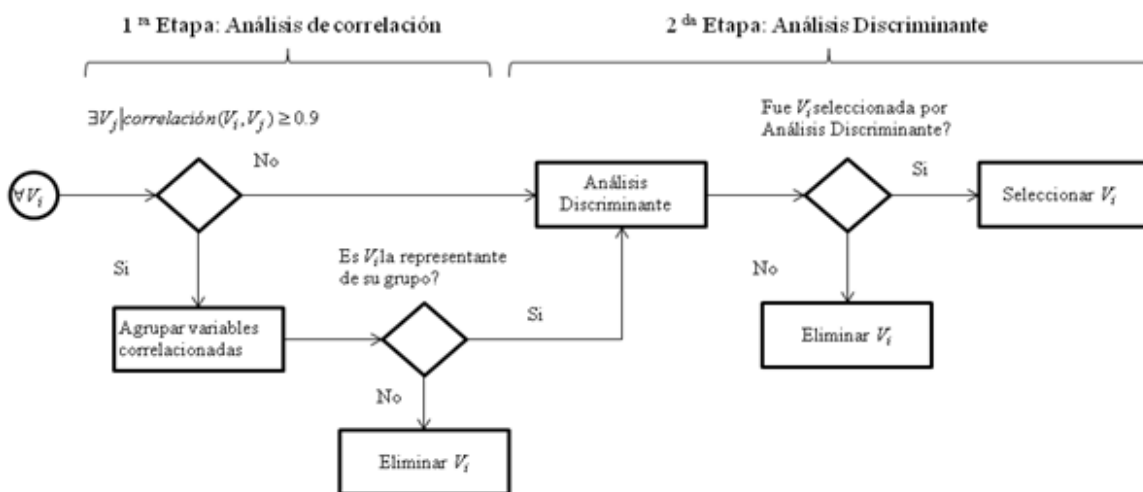


Figura 8.2 Diagrama de flujo del proceso de reducción del número de características. V_i y V_j representan a 2 características.

Cabe resaltar que el proceso de reducción de variables tiene por propósito principal la eliminación de características innecesarias para la clasificación, reduciendo el esfuerzo computacional. Esto, en algunos casos, puede tener el beneficio extra de eliminar sesgos por información repetida, mejorando el desempeño de los clasificadores. Sin embargo, al eliminar variables también se elimina información que podría ser útil para la clasificación, con lo que, en ocasiones, los algoritmos podrían tener una eficiencia ligeramente menor con el conjunto de variables reducidas. Considerando esto, no se espera que los algoritmos siempre mejoren su desempeño al emplear el conjunto

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta:
estudio comparativo

reducido de variables, sino que tengan una eficiencia similar con un coste computacional mucho menor, a excepción de algunos pocos casos.

8.2.1 Análisis de correlación simple.

En esta etapa de la reducción de características, se calcula la matriz de correlación entre las características de cada grupo de ensayos. Esta matriz depende del valor de las características de cada grupo, por lo que es diferente para cada uno de los 20 grupos considerados, pero no depende de la forma de clasificar los fallos.

Una vez calculada la matriz de correlación, se agrupan las variables indicativas de fallo con una correlación mayor a 0.9 y se elige una característica como representativa del grupo, descartándose las demás. Para ilustrar esta etapa, se muestra en la Tabla 8.3 una visión parcial de la matriz de correlación correspondiente al grupo de ensayos con alimentación de Red efectuados al Motor 2: M2 Red. En la Tabla 8.3 se muestran únicamente las características estadísticas del dominio del tiempo de la onda de corriente que presentaron una correlación significativa con alguna otra. Así, las características Momento 6, Curtosis, Factor de Cresta y Factor de Forma no se muestran por no haber presentado una correlación mayor a 0.9 con ninguna otra variable indicativa de fallo.

Tabla 8.3 Matriz de correlación para el grupo de ensayos M2 Red, vista parcial de los estadísticos correlacionados.

	2 ^{do} M	3er M	4to M	1er M	2do C	3er C	4to C	Skew	PVA	MVA	VCM
2 ^{do} M	1,00	0,01	0,99	0,05	1,00	-0,14	-1,00	-0,23	1,00	0,99	1,00
3er M		1,00	0,02	-0,13	0,01	0,21	-0,03	0,93	0,01	0,00	0,01
4to M			1,00	0,04	0,99	-0,12	-1,00	-0,22	0,99	0,97	0,98
1 ^{er} M				1,00	0,05	-0,98	-0,03	-0,10	0,06	0,11	0,06
2do C					1,00	-0,13	-1,00	-0,23	1,00	0,99	1,00
3er C						1,00	0,11	0,19	-0,14	-0,20	-0,15
4to C							1,00	0,21	-0,99	-0,98	-0,99
Skew								1,00	-0,24	-0,24	-0,24
PVA									1,00	0,99	1,00
MVA										1,00	0,99
VCM											1,00

En la Tabla 8.3, se puede observar que las características 2^{do} y 4^{to} Momento, 2^{do} y 4^{to} Cumulante, Promedio de Valores Absolutos (PVA), Máximo Valor Absoluto (MVA), y Valor Cuadrático Medio (VCM), presentan entre sí una alta correlación, por lo que el PVA se selecciona como representante del grupo y se eliminan las demás. El 1^{er}

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

Momento y el 3^{er} Cumulante tienen una correlación de -0.98, por lo que se eligió al 1^{er} Momento eliminándose al 3^{er} Cumulante. Finalmente, el 3^{er} Momento y la Skewness muestran una correlación de 0.93, por lo que se elimina al 3^{er} Momento y se mantiene a la Skewness. Este tratamiento se realizó con todas las características indicativas de fallo, tanto del dominio del tiempo como de la frecuencia. La Tabla 8.3 presenta una visión parcial de la matriz de correlación solamente por una cuestión de espacio y para ejemplificar el proceso de análisis de correlación simple efectuado.

Los resultados del análisis de correlación para los 20 grupos de ensayos se presentan en el Anexo 2.

8.2.2 Selección de características por Análisis Discriminante.

En esta segunda etapa del proceso de reducción del número de características, se utilizó el Análisis Discriminante, no como clasificador específicamente, sino para poder determinar las variables indicativas de fallo más relevantes para la clasificación.

En esta etapa no solamente importa el grupo de características, sino también la forma de clasificación que se pretenda hacer, es decir, si se pretende clasificar a los ensayos en los cuatro tipos de fallos considerados, F_{123} , o en alguno de las divisiones de fallos de acuerdo a la importancia del motor, descritas en la subsección previa, F_1 , F_2 o F_3 .

Como se describió en la Sección 4.3, el Análisis Discriminante tiene dos variantes para la selección de variables, paso a paso hacia adelante y paso a paso hacia atrás. En este trabajo se emplearon ambas variantes y, en caso de haber diferencias entre el grupo de características seleccionado, se utilizó el grupo que consiguió un mayor porcentaje de clasificación correcta. Como criterio de selección se eligió la F intergrupos (ver sección 4.2.2.2), por ser uno de los más utilizados en la literatura. En la Tabla 8.6 se presentarán las características seleccionadas en todos los casos propuestos en la Sección 8.1.

Esta etapa del proceso se ejemplificará con el grupo M2 Red, considerando la forma de clasificación F_{123} . Las características para el grupo M2 Red, después de la eliminación de variables altamente correlacionadas, son 21³:

- Las 8 características obtenidas mediante la transformada de Fourier: BI, BS, BI2, BS2, B5I, B5S, B7I y B7S.

³ La nomenclatura de las características se encuentra en las Tablas 6.1, 6.2 y 6.3

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

- Las 7 características estadísticas del dominio del tiempo: 1^{er} Momento, Skewness, MVA, 6to Momento, Curtosis, Factor de Cresta y Factor de Forma.
- Las seis características obtenidas mediante la Transformada de Hilbert, HI, HS, H5I, H5S, H7I y H7S.

Primeramente se realizó la selección de variables paso a paso hacia adelante, obteniéndose la matriz de confusión presentada en la Tabla 8.4, y se seleccionaron las características presentadas en la Tabla 8.5.

Tabla 8.4 Matriz de confusión para la selección de variables por Análisis Discriminante método paso a paso hacia adelante, para el grupo M2 Red, F₁₂₃.

Matriz de confusión					
Actual	Tamaño	Predicho	Fallo		
Fallo	de Grupo	Sano	Fallo Leve	Fallo Medio	Barra Rota
Sano	110	101	2	5	2
		-91,82%	-1,82%	-4,55%	-1,82%
Fallo Leve	40	0	40	0	0
		0,00%	-100,00%	0,00%	0,00%
Fallo Medio	42	2	0	36	4
		-4,76%	0,00%	-85,71%	-9,52%
Barra Rota	47	7	0	6	34
		-14,89%	0,00%	-12,77%	-72,34%
Porcentaje de casos correctamente clasificados: 88,28%					

Tabla 8.5 Características seleccionadas por Análisis Discriminante método paso a paso hacia adelante para el grupo M2 Red, F₁₂₃⁴.

Características calculadas con la Transformada de Fourier:	BI	BS2	B5I	B5S		
Características Estadísticas:	1 ^{er} C	MVA	6 ^{to} M	Curt	F C	FF
Características calculadas con la Transformada de Hilbert:	HS	H7I				

Se realizó el mismo análisis utilizando el método de selección de variables paso a paso hacia atrás obteniéndose el mismo resultado, por lo que las 12 características de la Tabla 8.5 son las finalmente seleccionadas para el grupo M2 Red, F₁₂₃. Como se mostró gráficamente en el Capítulo 7, las variables indicativas de fallo tienen distinto poder discriminante de acuerdo a la forma de clasificación que se pretenda hacer, por lo que la selección de variables por Análisis Discriminante se realizó para los 80 casos considerados.

A continuación se presenta la Tabla 8.6 donde se resumen todas las características seleccionadas por el Análisis Discriminante en cada caso. Al principio de cada columna

⁴ Forma de clasificación que discrimina entre los 4 estados de fallo considerados, ver Tabla 8.2.

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

se indica el grupo de ensayos, ver Tabla 8.1, y la forma de clasificación, ver Tabla 8.2. Cada fila corresponde a una de las características, con la nomenclatura explicada en las Tablas 6.1, 6.2 y 6.3. Se indica con un 1, si una característica ha sido seleccionada por el Análisis Discriminante para un caso particular y con una celda vacía si no ha sido seleccionada. Por ejemplo, la primera columna representa al M1, de todos los ensayos realizados con el Motor 1, forma de clasificación F_{123} , en dicha columna se observa que el primer Momento, 1^{er}M, tercer Momento, 3^{er} M y cuarto Cumulante, 4^{to} C, no han sido seleccionados para este caso, mientras que el sexto Momento, 6^{to} M, y el tercer Cumulante, 3^{er} C, sí han sido seleccionados. La última columna de la tabla indica el porcentaje de veces que cada característica ha sido seleccionada.

Observando la Tabla 8.6 notamos que las características que presentaban un alto poder discriminante en el análisis realizado en el capítulo 7 fueron seleccionadas por el Análisis Discriminante, como el Cumulante 3 para los ensayos del grupo M1 Red⁵, o el Momento 1 para el grupo Alt 65⁶. De las características que no presentaban poder discriminante a simple vista algunas fueron elegidas, como la Curtosis para el grupo M1, de todos los ensayos realizados con el Motor 1, demostrando que esta característica sí tiene un poder discriminante entre los estados de fallos cuando se asocia a otras características. Sin embargo, otras características que no presentaban un poder discriminante apreciables no fueron elegida finalmente, cómo el Skewness para el grupo de todos los ensayos realizados con el Motor 2. Este resultado nos demuestra que, para este grupo de ensayos, el Skewness no presenta poder discriminante en fallos ni siquiera en combinación con otras variables.

En la Tabla 8.6 no se presentan las variables 2^{do} Momento, 4^{to} Momento, 2^{do} Cumulante y Valor Cuadrático Medio (VCM), debido a que no fueron seleccionadas en ninguno de los casos.

⁵ Ver Tabla 8.1

⁶ Ver Tabla 8.1

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta:
estudio comparativo

Tabla 8.6 a. Resumen de características seleccionadas por el Análisis Discriminante. A la izquierda de cada fila se indica la característica y en la parte superior de cada fila el grupo de ensayos y la forma de clasificación⁷, si la característica ha sido seleccionada se indica con un “1” y con una celda vacía en caso contrario.

	Resumen de características seleccionadas por Análisis Discriminante																											
	M1				M1 50 Hz				Alt				Alt 35Hz				Alt 50Hz				Alt 65Hz				M1 Red			
	F ₁₂₃	F ₁	F ₂	F ₃	F ₁₂₃	F ₁	F ₂	F ₃	F ₁₂₃	F ₁	F ₂	F ₃	F ₁₂₃	F ₁	F ₂	F ₃	F ₁₂₃	F ₁	F ₂	F ₃	F ₁₂₃	F ₁	F ₂	F ₃	F ₁₂₃	F ₁	F ₂	F ₃
Desl.	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
Vel.	1	1	1	1					1	1	1	1																
BI	1	1	1	1	1	1	1	1	1	1	1	1	1		1				1		1	1	1	1	1	1	1	1
BS	1	1	1	1	1	1	1	1	1		1	1		1	1	1	1		1		1	1			1	1	1	1
BI2	1	1	1		1		1			1										1								
BS2									1	1	1									1								
B5I	1	1			1	1				1	1								1									
B5S	1	1		1	1	1	1	1		1	1					1		1				1			1	1		1
B7I				1	1			1	1			1				1								1	1	1	1	1
B7S																								1		1		1
1 ^{er} M					1		1	1													1	1	1	1				
3 ^{er} M																					1	1	1	1	1	1	1	
6 ^{to} M	1	1	1	1					1	1	1	1	1	1	1		1		1	1	1	1	1	1	1			
3 ^{er} C	1	1	1	1	1	1		1	1	1	1	1	1	1	1	1	1	1	1	1	1	1			1	1		1
4 ^{to} C																												
Skew	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1							1
Curt	1	1	1	1	1	1	1		1	1	1	1	1	1	1		1	1	1		1	1	1		1		1	1
PVA	1	1	1	1	1		1	1	1	1	1	1	1		1		1	1	1	1				1	1	1	1	1
MVA	1	1	1	1					1	1	1	1								1			1	1				
FC	1		1		1	1	1	1	1	1	1	1	1	1	1	1	1	1		1	1			1		1	1	
FF	1		1	1	1	1	1		1		1	1	1		1	1				1	1			1	1	1	1	1
HS	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1					1	1	1	1					
HS2	1		1		1		1		1		1	1			1	1									1			1
H5I	1	1	1	1	1	1	1	1	1			1											1		1	1	1	1
H5S	1	1	1	1		1				1	1		1		1												1	1
H7I							1													1				1				
H7S							1						1	1	1													1

⁷ En las Tablas 8.1 y 8.2 se describen los grupos de ensayos y formas de clasificación, en las Tablas 6.1, 6.2 y 6.3 la nomenclatura de las características.

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta:
estudio comparativo

Tabla 8.6 b. Resumen de características seleccionadas por el Análisis Discriminante. A la izquierda de cada fila se indica la característica y en la parte superior de cada fila el grupo de ensayos y la forma de clasificación⁸, si la característica ha sido seleccionada se indica con un “1” y con una celda vacía en caso contrario.

	Resumen de características seleccionadas por Análisis Discriminante																											
	M2				M2 65Hz				M2 50Hz				M2 35Hz				M2 Red				AB				AB35Hz			
	F ₁₂₃	F ₁	F ₂	F ₃	F ₁₂₃	F ₁	F ₂	F ₃	F ₁₂₃	F ₁	F ₂	F ₃	F ₁₂₃	F ₁	F ₂	F ₃	F ₁₂₃	F ₁	F ₂	F ₃	F ₁₂₃	F ₁	F ₂	F ₃	F ₁₂₃	F ₁	F ₂	F ₃
Desl.	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
Vel.	1	1	1	1																	1	1	1	1				
BI	1		1		1	1		1	1		1	1	1			1					1	1	1	1	1	1	1	1
BS	1	1	1	1	1		1	1	1	1	1		1	1			1	1	1	1	1	1	1	1				
BI2	1	1	1			1							1		1									1	1			1
BS2										1			1				1	1	1	1	1	1	1					
B5I	1		1		1		1	1	1	1	1		1	1	1		1	1	1	1	1	1	1	1	1	1	1	1
B5S	1	1	1	1	1	1	1	1	1	1	1		1	1	1	1	1	1	1	1	1	1	1	1		1	1	1
B7I	1	1	1	1	1	1	1	1	1	1	1		1			1					1	1		1	1	1	1	1
B7S			1		1		1	1		1	1		1	1		1					1	1	1	1	1	1	1	1
1 ^{er} M					1	1	1	1	1	1	1		1	1	1	1	1	1	1	1	1		1	1				
3 ^{er} M					1	1		1																				
6 ^{to} M					1												1	1	1	1								
3 ^{er} C					1	1		1	1	1	1										1		1	1				
4 ^{to} C																												
Skew							1		1	1	1										1	1		1	1		1	1
Curt	1	1						1	1	1		1		1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
PVA					1			1	1								1	1	1	1			1					1
MVA											1										1							
FC	1	1				1			1	1			1	1			1	1	1	1	1	1	1	1	1	1	1	1
FF	1	1		1	1		1	1	1	1		1	1		1	1	1	1	1	1	1	1	1	1	1	1	1	1
HS	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
HS2		1											1		1	1												
H5I				1	1	1	1		1	1	1		1	1	1	1										1	1	
H5S	1	1							1	1			1								1	1		1		1		
H7I	1		1	1					1		1	1	1		1	1	1	1	1	1								1
H7S	1			1	1			1																		1	1	

⁸ En las Tablas 8.1 y 8.2 se describen los grupos de ensayos y formas de clasificación, en las Tablas 6.1, 6.2 y 6.3 la nomenclatura de las características.

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta:
estudio comparativo

Tabla 8.6c. Resumen de características seleccionadas por Análisis Discriminante. A la izquierda de cada fila se indica la característica y en la parte superior de cada fila el grupo de ensayos y la forma de clasificación⁹, si la característica ha sido seleccionada se indica con un "1" y con una celda vacía en caso contrario. La última columna indica el porcentaje de casos que cada característica fue seleccionada.

	Resumen de características seleccionadas por Análisis Discriminante																								Porcentaje sobre el total				
	AB50Hz				AB65Hz				SM				SM35Hz				SM50Hz				SM65Hz								
	F ₁₂₃	F ₁	F ₂	F ₃	F ₁₂₃	F ₁	F ₂	F ₃	F ₁₂₃	F ₁	F ₂	F ₃	F ₁₂₃	F ₁	F ₂	F ₃	F ₁₂₃	F ₁	F ₂	F ₃	F ₁₂₃	F ₁	F ₂	F ₃					
Desl.	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	
Vel.									1	1	1	1																	
BI			1		1		1	1							1			1							1				62,5%
BS	1	1	1	1	1		1	1	1	1	1		1	1		1		1			1				1	1	1		71,3%
BI2						1	1	1		1	1		1	1	1	1													31,3%
BS2	1								1																		1		16,3%
B5I	1		1	1	1	1		1	1	1	1	1	1		1		1		1	1	1	1	1	1	1	1	1		56,3%
B5S	1			1	1			1			1	1	1	1	1	1									1		1		61,3%
B7I	1		1	1	1	1	1	1	1			1	1			1											1		53,8%
B7S	1	1	1			1	1					1			1												1	1	36,3%
1 ^{er} M	1		1		1		1		1	1	1	1	1	1		1			1		1	1	1	1	1	1	1	1	50,0%
3 ^{er} M																			1	1	1	1		1			1		17,5%
6 ^{to} M																													27,5%
3 ^{er} C		1			1		1		1	1	1	1									1	1	1	1	1	1	1	1	55,0%
4 ^{to} C								1																					1,3%
Skew									1	1	1		1	1	1	1	1				1	1	1	1	1	1	1	1	58,8%
Curt	1	1			1		1		1	1		1	1			1	1	1			1	1	1	1	1	1	1	1	71,3%
PVA		1	1						1	1	1						1	1	1	1	1	1		1	1	1		1	53,8%
MVA	1	1							1	1	1	1					1	1	1	1									28,8%
FC	1				1				1	1	1	1	1	1			1	1	1										55,0%
FF		1			1	1			1	1	1		1	1	1	1					1	1	1				1		68,8%
HS	1		1	1	1	1	1	1	1	1	1	1	1		1	1	1		1	1	1	1	1	1	1	1	1	1	85,0%
HS2					1			1							1														22,5%
H5I					1	1		1	1	1	1	1	1	1	1	1	1				1				1	1	1		55,0%
H5S													1	1				1											28,8%
H7I									1	1		1	1	1	1	1													27,5%
H7S																													15,0%

⁹ En las Tablas 8.1 y 8.2 se describen los grupos de ensayos y formas de clasificación, en las Tablas 6.1, 6.2 y 6.3 la nomenclatura de las características.

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

Analizando la Tabla 8.6 se pueden extraer las siguientes conclusiones:

- La característica más seleccionada fue la banda superior al primer armónico calculada con la Transformada de Hilbert, en el 85% de los casos.
- La banda superior o la banda inferior al 1^{er} armónico calculadas por la Transformada de Fourier son seleccionadas (al menos una de las dos) en el 90% de los casos.
- En el 100% de los casos se seleccionó al menos una característica calculada por medio de la Transformada de Fourier.
- En el 97,5% de los casos se seleccionó al menos una característica estadística. Solamente en M2 F₂ y AB 50Hz F₃ no se seleccionó ninguna característica estadística.
- De las 29 características originales finalmente se seleccionaron 11,1 en promedio, es decir, se redujo el número de características a un 38,3%. De todos los casos, el que menos variables seleccionó fue el SM 50Hz F₃ con sólo 4 características (el 13,8% del original) y el que más necesitó fue el M1 F₁₂₃, con 17 variables (el 58,6% del original).
- De las variables calculadas por la Transformada de Hilbert propuestas en esta tesis, HS2, H5I, H5S, H7I y H7S, alguna es seleccionada en el 78,8% de los casos, es decir 63 veces.

En [PUC09] se utiliza el Módulo de la Señal Analítica para calcular la primera banda lateral superior al primer armónico. Es necesario recordar que en esta tesis se propone extender esta metodología para calcular otras bandas características de fallo por barras rotas, como la segunda banda lateral superior al primer armónico, H2S y las bandas laterales alrededor del 5^{to} y 7^{mo} armónico, H5I, H5S, H7I y H7S respectivamente. En los resultados presentados en la Tabla 8.5 se puede apreciar que de estas características, la más seleccionada fue H5I, banda lateral inferior al 5^{to} armónico, siendo elegida como relevante para la clasificación en más de la mitad de los casos, 55%. La característica menos seleccionada, H7S, mostró ser relevante para la clasificación en al menos algunos casos, el 15% de los mismos.

Considerando que en el 78,8% de los casos, casi 4 de cada 5, se seleccionó al menos una de las características calculadas por la Transformada de Hilbert aquí propuestas, se

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

puede concluir que es conveniente extender esta metodología para calcular las bandas laterales también a armónicos superiores.

Cabe resaltar que en esta sección se utilizó el Análisis Discriminante como metodología para seleccionar variables, sin considerar la eficiencia del algoritmo para clasificar los ensayos de cada caso. Para seleccionar las variables, el Análisis Discriminante utiliza todos los ensayos y recibe cada ensayo con la información del tipo de fallo del mismo.

8.3 Clasificación por medio de Análisis Discriminante.

En esta sección se presentan los resultados del Análisis Discriminante utilizado como clasificador y evaluado mediante validación cruzada de 10 iteraciones (ver Sección 6.4 b). De esta forma, para realizar el entrenamiento, el algoritmo recibe primero un grupo de ensayos que contienen la información del tipo de fallo, y luego se presenta al algoritmo un conjunto de ensayos, llamado grupo de validación, sin la información de su tipo de fallo para comprobar la eficiencia de clasificación del método para este grupo de validación. De esta forma los resultados de esta sección son diferentes a los obtenidos en la sección anterior y generalmente peores.

8.3.1 Alimentación con red.

Primeramente se presentan los resultados del Análisis Discriminante como clasificador para los grupos de ensayos obtenidos con alimentación de red, tanto para el Motor 1 como el Motor 2.

a) Motor 1

El Análisis Discriminante tuvo muy buen desempeño para clasificar los ensayos del Motor 1 con alimentación de Red. Considerando el conjunto de 29 variables originales clasificó en promedio el 99,1% de los ensayos para la forma de clasificación F_{123} y obtuvo el 100% de clasificación correcta utilizando el grupo de características reducido de acuerdo al proceso descrito en la sección anterior. En la Fig. 8.3 se muestra un gráfico de caja y bigotes (también conocido *boxplots* o *box and whiskers plots*) con los porcentajes de clasificación correcta ponderados, obtenidos por el Análisis Discriminante para F_{123} tanto con las variables originales, como con las variables reducidas. Como se puede ver en la Fig. 8.3, solamente en algunas pocas oportunidades

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta:
estudio comparativo

el algoritmo no logró clasificar correctamente todos los ensayos cuando utilizaba al conjunto de variables originales, comparando con el conjunto de variables reducido.

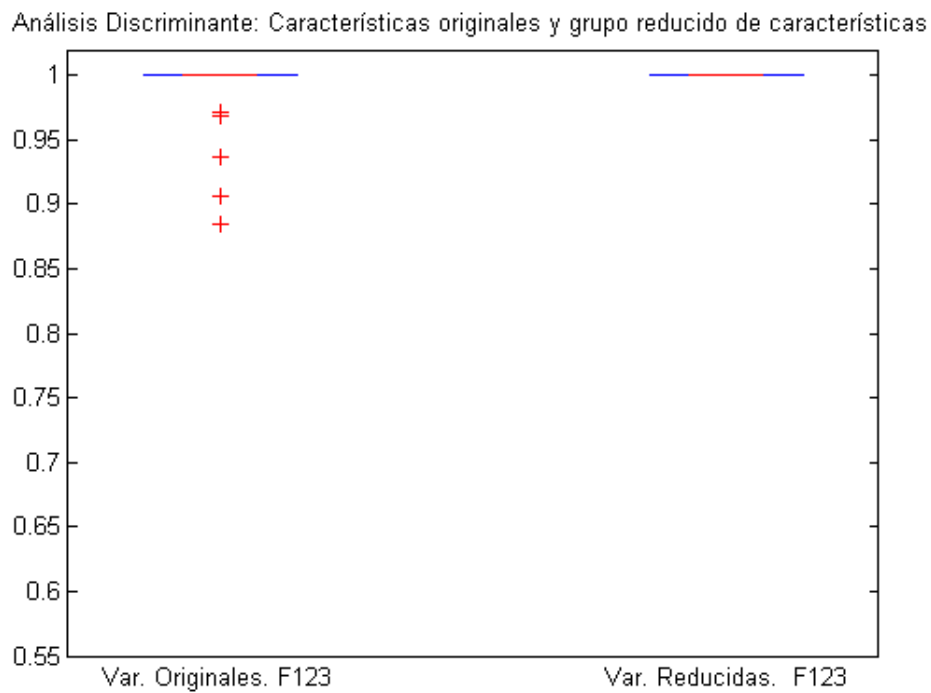


Figura 8.3 Gráfico de caja y bigotes para los resultados de Análisis Discriminantes para el caso M1Red
F₁₂₃.




Figura 8.4 Gráfico de caja y bigotes para los resultados de Análisis Discriminantes para los casos M1Red
F₁, F₂, y F₃.

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

Los resultados del algoritmo para las formas de clasificación F_1 , F_2 y F_3 se muestran en la Fig. 8.4, primero considerando todas las características, “VO.”, y luego utilizando sólo el conjunto reducido de variables, “VR”. En la mayoría de los casos el porcentaje de clasificación correcta ponderada es superior al 99%. Solamente cuando se considera F_3 con el conjunto de características originales se obtuvo una clasificación correcta del 91,8%, es decir, solamente la separación de los ensayos con Barra Rota del resto utilizando las variables originales no consiguió llegar al 99% de clasificación correcta.

Puede verse que, para este grupo de ensayos, con la reducción de variables indicativas de fallo, no solamente se mantuvo el nivel de clasificación correcta, sino que inclusive se obtuvo una ligera mejora.

b) Motor 2

El desempeño del Análisis Discriminante al clasificar los ensayos del grupo M2 Red es significativamente inferior al mostrado en el caso anterior. Para este grupo de ensayos, considerando la forma de clasificación F_{123} , se alcanzaron unos porcentajes de clasificación correcta ponderada de 69,5% y 85,6% utilizando el conjunto original de características y el reducido respectivamente. La Fig. 8.5 muestra los resultados del Análisis Discriminante para el caso M2 Red F_{123} . En la Fig. 8.6 se presenta el desempeño de esta metodología para los casos M2 Red F_1 , F_2 y F_3 . También en estos casos se puede apreciar que la reducción de variables no solamente disminuye el esfuerzo computacional requerido por el algoritmo sino que también mejora visiblemente el desempeño del mismo.

Observando la Fig. 8.6 se pone de manifiesto que, en las formas de clasificación F_1 y F_2 , la mejora del desempeño, al reducir las variables, es bastante obvia para el caso M2 Red F_3 ; sin embargo, es solamente del 2%, mejorando del 83,1% al 85,5% en promedio al implementar el algoritmo con el conjunto de variables reducido.

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

Análisis Discriminante: Características originales y grupo reducido de características

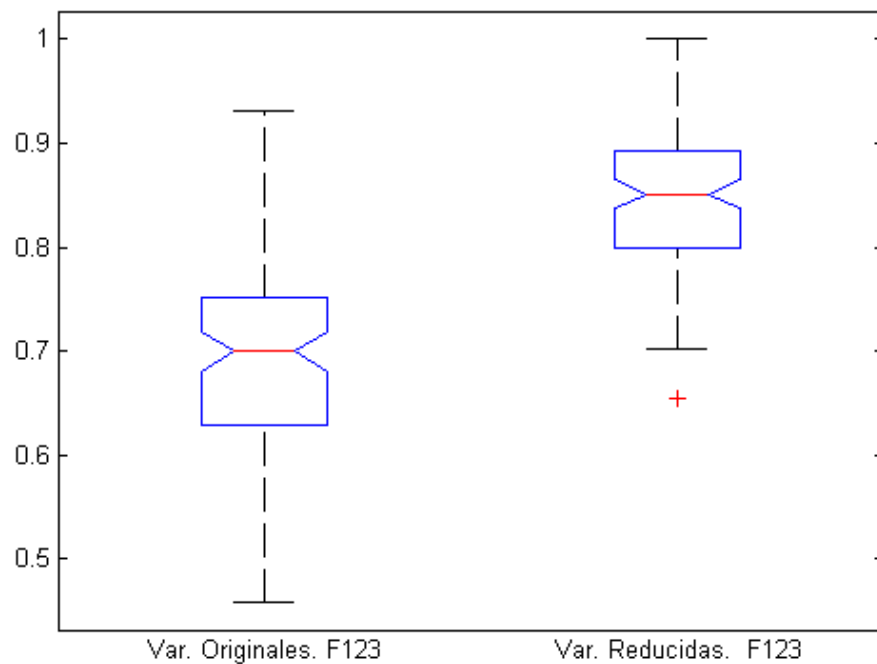


Figura 8.5 Gráfico de caja y bigotes para los resultados de Análisis Discriminantes para el caso M2Red F_{123} .

Análisis Discriminante: Características originales y grupo reducido de características




Figura 8.6 Gráfico de caja y bigotes para los resultados de Análisis Discriminantes para los casos M2Red F_1 , F_2 , y F_3 .

8.3.2 Resumen con las diferentes combinaciones de alimentaciones consideradas.

En esta sección, a modo de ejemplo del desempeño obtenido, se presentan los resultados del Análisis Discriminante sólo para algunos casos de todos los considerados. En la Tabla 8.7 se presentará más adelante un resumen del desempeño promedio del algoritmo para los 80 casos estudiados.

a) *Ensayos Alt 65*

Considerando al grupo de ensayos Alt65 Hz, estos son los resultados obtenidos con el Motor 1 y alimentación de variador Altivar a 65 Hz, considerando la forma de clasificación F_{123} , es decir, la forma de clasificación que discrimina los ensayos en las cuatro clases o estados de fallo considerados. El desempeño del algoritmo es perfecto, tanto si se utilizan las variables originales como si se emplea el conjunto reducido de características, como se comprueba en la Fig. 8.7.

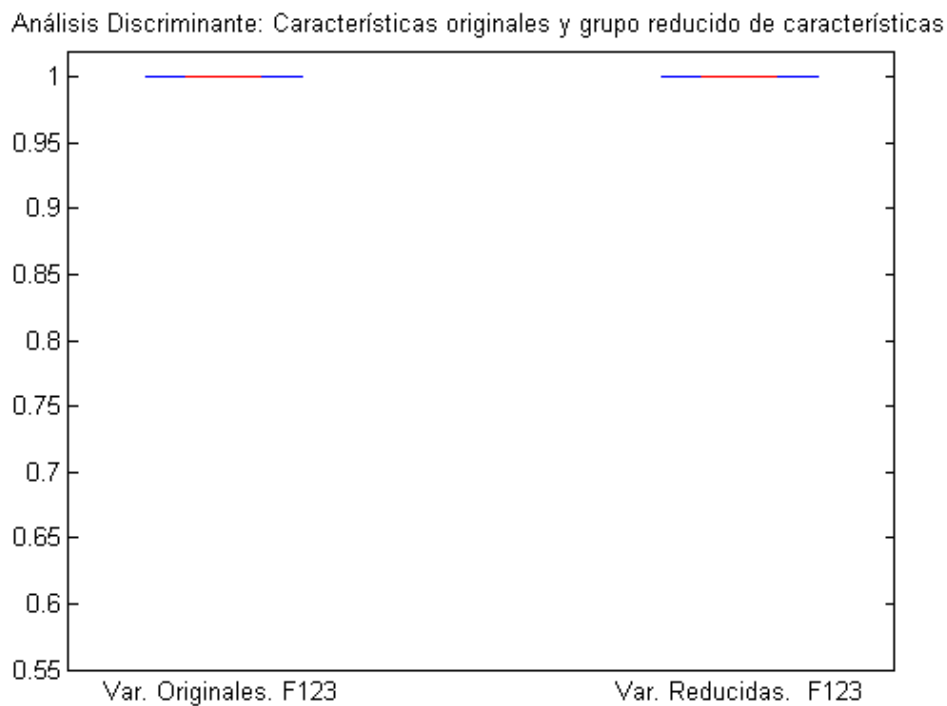


Figura 8.7 Gráfico de caja y bigotes para los resultados de Análisis Discriminantes para el caso Alt65 F_{123} .

La Fig. 8.8 presenta los resultados del Análisis Discriminante para las formas de clasificación F_1 , F_2 y F_3 (ver Tabla 8.2). Se puede observar que el porcentaje de clasificación correcta es muy elevado. El caso Alt65 F_1 es uno de los pocos casos del

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

Motor 1 en el que el porcentaje de clasificación disminuye ligeramente al reducir el conjunto de características, aunque es sólo del 0,1 % (ver Tabla 8.7).




Figura 8.8 Gráfico de caja y bigotes para los resultados de Análisis Discriminantes para los casos Alt65 F_1 , F_2 , y F_3 .

b) Ensayos AB

A continuación se presentan los resultados del Análisis Discriminante aplicado al conjunto de ensayos obtenidos con el Motor 2 y alimentación con variador Allen Bradley a 35 Hz, 50 Hz y 65 Hz. La Fig. 8.9 presenta los resultados del Análisis Discriminante considerando la forma de clasificación F_{123} para el conjunto original de características y el grupo reducido de variables indicativas de fallo. En este caso se puede apreciar la mayor mejora del desempeño del algoritmo al reducir el número de variables, pues con el conjunto original de características el promedio de porcentaje de clasificación correcto es de 65,5 y después de reducir el número de características, el desempeño se eleva hasta el 90,5%, es decir, una mejora del 24,9%.

En la Fig. 8.10 pueden verse también los resultados para las formas de clasificación F_1 , F_2 y F_3 . En todos estos casos se evidencia una clara mejora del porcentaje de clasificación correcta al reducir el número de características.

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta:
estudio comparativo




Figura 8.9 Gráfico de caja y bigotes para los resultados de Análisis Discriminantes para el caso AB F_{123} .




Figura 8.10 Gráfico de caja y bigotes para los resultados de Análisis Discriminantes para los casos AB F_1 , F_2 , y F_3 .

c) Ensayos SM50 Hz

En esta sección se muestran los resultados del Análisis Discriminante para los ensayos realizados con el Motor 2 y alimentación de variador Siemens a 50 Hz. Como en las secciones precedentes, se muestran primero los resultados para la forma de clasificación F_{123} , para el grupo original de características y para el grupo reducido de variables en la Fig. 8.11, y luego se presentan los resultados para las formas de clasificación F_1 , F_2 y F_3 en la Fig. 8.12.

En la Figura 8.12 se observa que, para las formas de clasificación F_1 , y F_3 , el desempeño del algoritmo mejora como resultado del proceso de reducción del número de variables. Sin embargo, considerando F_2 , el desempeño disminuye del 92,3 % al 90,8 %, un 1,4 %. Este caso, se produce la mayor disminución de la eficiencia en la clasificación del Análisis Discriminante al reducir la cantidad de variables y entre todos los casos considerados en este trabajo.

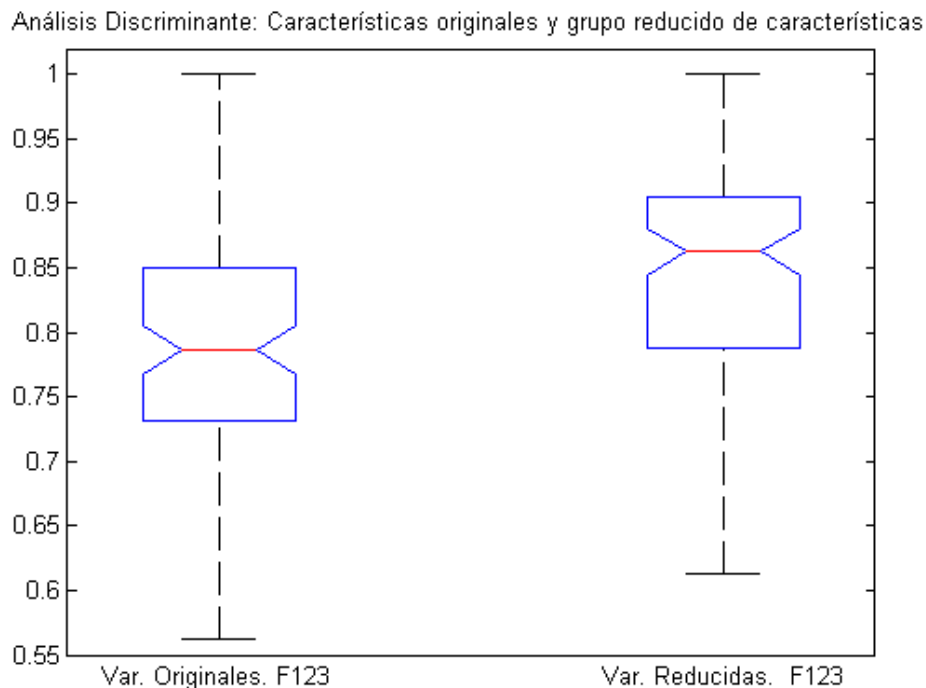


Figura 8.11 Gráfico de caja y bigotes para los resultados de Análisis Discriminantes para el caso SM50

F_{123} .

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo




Figura 8.12 Gráfico de caja y bigotes para los resultados de Análisis Discriminantes para los casos SM50 F₁, F₂, y F₃.

A continuación, se presenta la Tabla 8.7 a, b y c, que resume todos los resultados obtenidos con el Análisis Discriminante para todos los grupos de ensayos y para las formas de clasificación F₁₂₃, F₁, F₂ y F₃ (ver Tabla 8.2). Se presenta tanto el desempeño con el conjunto original de características, “Var. Ori.”, como con el conjunto reducido de las mismas, “Var. Red”. Se puede apreciar como en la mayoría de los casos el desempeño mejora al reducir la cantidad de variables y que los ensayos realizados al Motor 1 con todos los tipos de alimentación son mucho más fáciles de clasificar correctamente por el algoritmo que los ensayos realizados al Motor 2.

En la última columna de la Tabla 8.7 c se observan los promedios del porcentaje de clasificación correcta obtenidos por el Análisis Discriminante para todos los casos. Se puede apreciar que el mejor desempeño corresponde a la forma de clasificación F₂, la forma de clasificación que separa a los ensayos de motor Sano y con Fallo Leve de aquellos con Fallo Medio o Barra Rota. Observando que el desempeño para las formas de clasificación F₁ y F₃ es similar, 93,8% y 93,2% respectivamente, se puede concluir que el algoritmo puede separar los ensayos con Motor Sano de los demás con la misma eficiencia que discrimina los ensayos de Barra Rota del resto.

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

Tabla 8.7 a Resumen de resultados del Análisis Discriminante para todos los casos. Se presenta el porcentaje de clasificación correcta para los algoritmos empleando el conjunto original de variables, Var. Ori. y el conjunto reducido, Var. Red., para las 4 formas de clasificación consideradas, F_{123} , F_1 , F_2 y F_3 .

	M1	M1 50 Hz	Alt	Alt 35Hz	Alt 50Hz	Alt 65Hz	M1 Red
Var. Ori. F_{123}	80,7%	82,0%	94,4%	99,4%	100,0%	100,0%	99,1%
Var. Red. F_{123}	97,5%	99,9%	98,3%	100,0%	100,0%	100,0%	100,0%
Var. Ori. F_1	83,5%	84,6%	89,5%	86,5%	89,4%	99,7%	99,4%
Var. Red. F_1	97,6%	99,8%	97,4%	100,0%	100,0%	99,5%	99,8%
Var. Ori. F_2	99,4%	99,0%	99,1%	100,0%	99,9%	100,0%	99,0%
Var. Red. F_2	99,4%	100,0%	99,4%	100,0%	100,0%	100,0%	100,0%
Var. Ori. F_3	92,8%	95,0%	92,4%	95,2%	100,0%	95,8%	91,8%
Var. Red. F_3	99,6%	99,5%	100,0%	100,0%	100,0%	100,0%	99,6%

Tabla 8.7 b Resumen de resultados del Análisis Discriminante para todos los casos. Se presenta el porcentaje de clasificación correcta para los algoritmos empleando el conjunto original de variables, Var. Ori. y el conjunto reducido, Var. Red., para las 4 formas de clasificación consideradas, F_{123} , F_1 , F_2 y F_3 .

	M2	M2 65Hz	M2 50Hz	M2 35Hz	M2 Red	AB	AB35Hz
Var. Ori. F_{123}	59,4%	69,3%	63,9%	75,5%	69,5%	65,6%	89,6%
Var. Red. F_{123}	69,0%	85,6%	76,0%	83,7%	84,6%	90,5%	92,2%
Var. Ori. F_1	72,1%	78,7%	71,6%	88,2%	74,2%	76,4%	89,5%
Var. Red. F_1	81,9%	85,5%	85,4%	94,0%	90,1%	88,6%	93,7%
Var. Ori. F_2	88,5%	93,2%	86,7%	94,4%	85,9%	94,1%	92,5%
Var. Red. F_2	93,1%	94,5%	90,8%	95,6%	91,7%	96,2%	95,7%
Var. Ori. F_3	81,0%	83,8%	82,2%	85,6%	83,1%	86,8%	91,9%
Var. Red. F_3	85,2%	94,3%	82,3%	87,0%	85,5%	94,6%	97,0%

Tabla 8.7 c Resumen de resultados del Análisis Discriminante para todos los casos. Se presenta el porcentaje de clasificación correcta para los algoritmos empleando el conjunto original de variables, Var. Ori. y el conjunto reducido, Var. Red., para las 4 formas de clasificación consideradas, F_{123} , F_1 , F_2 y F_3 , la última columna muestra el promedio de todos los casos.

	AB50Hz	AB65Hz	SM	SM35Hz	SM50Hz	SM65Hz	Promedio
Var. Ori. F_{123}	80,5%	86,9%	71,1%	90,2%	78,6%	85,4%	81,7%
Var. Red. F_{123}	90,6%	96,1%	73,6%	95,3%	84,9%	93,0%	90,2%
Var. Ori. F_1	75,6%	77,8%	83,2%	90,1%	88,7%	94,4%	84,8%
Var. Red. F_1	90,8%	93,3%	83,1%	99,4%	95,2%	99,9%	93,8%
Var. Ori. F_2	94,3%	96,4%	93,1%	95,6%	92,3%	91,1%	94,7%
Var. Red. F_2	97,3%	96,6%	92,6%	97,1%	90,8%	95,4%	96,3%
Var. Ori. F_3	89,1%	87,0%	83,1%	86,3%	75,4%	91,1%	88,3%
Var. Red. F_3	91,7%	99,4%	82,2%	96,4%	79,5%	96,5%	93,2%

En la Tabla 8.8 se resume el efecto de la reducción del número de características en el desempeño del Análisis Discriminante. Se puede concluir que, para este algoritmo, el reducir la cantidad de variables no sólo tiene el efecto beneficioso de disminuir el esfuerzo computacional requerido para calcular dichas características e implementar el

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

método en sí, sino que además consigue una mejora significativa del porcentaje de clasificación correcta ponderada obtenido por el algoritmo, en promedio el 6%.

Tabla 8.8 Resumen de diferencia del desempeño del Análisis Discriminante al reducir el número de variables. Se presenta el promedio de las diferencias de desempeño antes y después de reducir las variables, el máximo aumento y la máxima disminución de desempeño tras la reducción de variables.

Diferencia en el desempeño del Análisis Discriminante al reducir el número de características para las formas de clasificación:	Promedio	Máximo aumento	Máxima disminución
F ₁₂₃	8,5%	24,9%	0,0%
F ₁	8,9%	15,8%	-0,1%
F ₂	1,6%	5,8%	-1,4%
F ₃	4,9%	12,5%	-0,8%
	6,0%	14,7%	-0,6%

8.4 Clasificación por medio de Regresión Logística.

En la presente sección se muestran los resultados obtenidos por la Regresión Logística, evaluada de forma similar al Análisis Discriminante, es decir, utilizando un esquema de validación cruzada de 10 iteraciones, repetido 10 veces y promediando los resultados. Cabe destacar que la división de los grupos es la misma que se utilizó para el Análisis Discriminante, es decir, primero se dividió el conjunto de ensayos en los grupos necesarios y se guardó esta división para poder ser utilizada por todos los algoritmos evaluados en este trabajo.

Siguiendo el esquema utilizado para presentar los resultados obtenidos con el Análisis Discriminante, primeramente se mostrarán los resultados obtenidos para los ensayos realizados con alimentación de red, tanto para el Motor 1 como para el Motor 2. Seguidamente se mostrarán los resultados de la Regresión Logística para algunos casos significativos, a fin de ejemplificar los resultados en los demás casos. Finalmente se expondrán en tablas un resumen general del desempeño de la Regresión Logística para todos los casos considerados.

8.4.1 Alimentación con red.

a) *Motor 1*

En la Fig. 8.13 se puede apreciar un gráfico de caja y bigotes con los porcentajes de clasificación correcta ponderada para la Regresión Logística con el conjunto original de variables y para el conjunto reducido de características. Se considera la forma de

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta:
estudio comparativo

clasificación F_{123} , es decir, se clasifica en las cuatro clases consideradas, ver en Tabla 8.2 la definición de las formas de clasificación.




Figura 8.13 Gráfico de caja y bigotes para los resultados de Regresión Logística para el caso M1Red F_{123} .




Figura 8.14 Gráfico de caja y bigotes para los resultados de Regresión Logística para los caso M1Red F_1 , F_2 y F_3 .

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

Debido al buen desempeño tanto del Análisis Discriminante como de la Regresión Logística, esta figura es muy parecida a la Fig. 8.3, es decir, en ambos casos los algoritmos consiguieron clasificar correctamente casi todos los ensayos.

En la Fig. 8.14 se observa un gráfico de caja y bigotes con los resultados de la Regresión Logística para los grupos de ensayos M1Red F₁, M1Red F₂, y M1Red F₃. Se aprecia que el desempeño de la Regresión Logística se mantiene igual al disminuir la cantidad de características utilizadas para las tres formas de clasificar F₁, F₂ y F₁ clasificando erróneamente sólo algunos pocos ensayos.

b) Motor 2

Las Figs. 8.15 y 8.16 presentan los resultados de la Regresión Logística para el grupo de ensayos realizados al Motor 2 con alimentación de red. En la Fig. 8.15 se aprecia en el gráfico de caja y bigotes los porcentajes de clasificación correcta ponderada para este algoritmo, a la izquierda utilizando todas las variables y a la derecha empleando sólo el grupo reducido de características. El porcentaje promedio de clasificación correcta de la Regresión Logística con las variables originales fue de 86,9 y al disminuir la cantidad de características el desempeño baja ligeramente hasta el 86,4 %.




Figura 8.15 Gráfico de caja y bigotes para los resultados de Regresión Logística para el caso M2Red F₁₂₃.

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

En la Fig. 8.16 observamos el desempeño de la Regresión Logística considerando las formas de clasificar F_1 , F_2 y F_3 . A diferencia de lo que ocurre con la clasificación F_{123} con el motor M1 en los casos presentados en la Fig. 8.14, el desempeño del método de clasificación mejora al trabajar con menor cantidad de variables. Así, al separar los ensayos Sanos del resto, clasificación F_1 , la clasificación correcta de la Regresión Logística se incrementa de 88% al 90,2%. En el segundo tipo de clasificación, F_2 , que separa los ensayos Sanos o con Fallo Leve de aquellos con Fallo Medio o Barra Rota, el desempeño mejora del 87,9% al 91,8% en promedio al disminuir la cantidad de características. Finalmente, al separar los ensayos con Barra Rota de los demás, también se mejora el porcentaje de clasificación de un promedio del 83,2 % al utilizar todas las características, al 90,4 % al emplear solamente las variables consideradas como relevantes para la clasificación por el Análisis Discriminante.




Figura 8.16 Gráfico de caja y bigotes para los resultados de Regresión Logística para los caso M2Red F_1 , F_2 y F_3 .

8.4.2 Resumen con las diferentes combinaciones de alimentaciones consideradas.

A continuación se muestran los resultados de la Regresión Logística para tres grupos de ensayos, todos los obtenidos con el Motor 1 y el variador Altivar, todos los obtenidos a

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

35 Hz con el Motor 2, y ensayos realizados con el Motor 2 y alimentación con variador Allen Bradley a 35 Hz.

a) Ensayos Alt

En esta sección se muestran los resultados de la Regresión Logística empleando los ensayos realizados al Motor 1 con el convertidor Altivar a las tres frecuencias consideradas en esta tesis, 35 Hz, 50 Hz y 65 Hz. Primeramente, en la Fig. 8.17, se presentan los resultados para el caso en que se clasifican los ensayos en las cuatro clases: Motor Sano, Fallo Leve, Fallo Medio y Barra Rota. Con esta forma de clasificación la Regresión Logística obtuvo un promedio de clasificación correcta ponderada de 98 y 99,3 % al utilizar todas las características y el conjunto reducido de variables respectivamente.




Figura 8.17 Gráfico de caja y bigotes para los resultados de Regresión Logística para el caso M1 Alt F₁₂₃.

En la Fig. 8.18 se presentan los resultados de la Regresión Logística para las clasificaciones F₁, F₂ y F₃. Para la clasificación F₁, el porcentaje de clasificación correcta disminuye ligeramente del 99,6% al 99,1%, sin que esto pueda ser considerado como una variación significativa. Sin embargo, para las otras dos formas de

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

clasificación el desempeño del algoritmo se mantiene al reducir la cantidad de características empleadas.




Figura 8.18 Gráfico de caja y bigotes para los resultados de Regresión Logística para los caso M1 Alt F₁, F₂ y F₃.

b) Ensayos M2 a 35 Hz

En las Figs. 8.19 y 8.20 se muestran los resultados para el grupo de ensayos obtenidos con el Motor 2 a 35 Hz, incluyendo las pruebas hechas con el variador Allen Bradley a 35 Hz y las realizadas con el convertidor Siemens también a 35 Hz. La Fig. 8.19 presenta un gráfico de caja y bigotes para los resultados de la forma de clasificar F₁₂₃ y la Fig. 8.20 hace lo propio con los resultados para F₁, F₂ y F₃. Este caso tuvo las mayores disminuciones de desempeño del algoritmo al reducir la cantidad de variables. Así, para la clasificación F₁₂₃ el porcentaje de clasificación correcta disminuye del 94,7 % utilizando todas las variables al 85,1 % empleando el grupo reducido. En la Fig. 8.20 se muestran los resultados para las formas de clasificación F₁, F₂ y F₃. En esta gráfica se aprecia que también para las clasificaciones F₁ y F₃ el porcentaje de clasificación disminuye al reducir la cantidad de variables. Así, para el caso F₁ la clasificación correcta baja del 97,7 al 95,8 % y para F₃ disminuye del 96,8 al 86,1%. Sin embargo,

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

para la clasificación tipo F_2 el desempeño de la Regresión Logística mejora del 95,5 al 96,5% al utilizar el conjunto reducido de características.

Se puede destacar la dificultad de mezclar ensayos realizados con diferentes tipos de alimentación debido a que las características pueden tener un comportamiento diferente con cada alimentador. Por ejemplo, comparando la Fig. 7.23 que muestra el comportamiento del Factor de Forma con el variador Allen Bradley a 35 Hz con la Fig. 7.31 que muestra la misma característica con el alimentador Siemens también a 35 Hz, podemos apreciar la diferencia entre ambas. Así, con el variador Allen Bradley los ensayos de Motor Sano y Fallo Medio tienen valores similares entre sí y visiblemente diferentes a los ensayos de Fallo Leve o Barra Rota, sin embargo, con el variador Siemens son los ensayos de Barra Rota los que tienen valores de Factor de Forma similares a los ensayos de Motor Sano y diferentes de los ensayos con Fallo Leve o Fallo Medio.




Figura 8.19 Gráfico de caja y bigotes para los resultados de Regresión Logística para el caso M2 35 Hz F_{123} .

Otro aspecto que complica la correcta clasificación de los ensayos realizados a la frecuencia de 35 Hz es que la frecuencia de las bandas lateras relacionadas con el fallo es directamente proporcional a la frecuencia fundamental, ver sección 2.4.2. Por lo que

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

mientras más baja sea la frecuencia a la que opere el motor, más cercanas estarán las bandas laterales al armónico fundamental (o 5^{to} o 7^{mo} armónico según sea el caso), y más difícil será poder calcular correctamente la amplitud de dichas bandas laterales, sobre todo a deslizamientos bajos.

Los resultados presentados en esta sección representan el caso en el que la reducción de variables tuvo el mayor efecto negativo en el desempeño de la Regresión Logística. Cabe resaltar que, en la mayoría de los casos, la diferencia de la eficiencia del algoritmo al reducir la cantidad de características no fue significativa y, como se verá más adelante, el promedio del desempeño de la Regresión Logística no se vio afectado por la reducción del número de variables.




Figura 8.20 Gráfico de caja y bigotes para los resultados de Regresión Logística para los caso M2 35 Hz F_1 , F_2 y F_3 .

c) Ensayos AB 50

En esta sección se presentan los resultados para uno de los casos en que utilizar el conjunto de variables reducido mejora en mayor medida el desempeño de la Regresión Logística. En las Figs. 8.21 y 8.22 se muestran los resultados para el conjunto de ensayos obtenidos con el Motor 2 alimentado con variador Allen Bradley a 50 Hz. En la Fig. 8.21 se observa el desempeño de la Regresión Logística para la clasificación F_{123} ,

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta:
estudio comparativo

en esta situación el algoritmo mejora su porcentaje de clasificación correcta del 88,4 al 93,6 % al utilizar el grupo reducido de variables.




Figura 8.21 Gráfico de caja y bigotes para los resultados de Regresión Logística para el caso AB50 F₁₂₃.




Figura 8.22 Gráfico de caja y bigotes para los resultados de Regresión Logística para los caso AB50 F₁,
F₂ y F₃.

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

En la Fig. 8.22 se muestran los resultados de la Regresión Logística para las clasificaciones F_1 , F_2 y F_3 . Se puede notar que el desempeño del algoritmo mejora al utilizar el conjunto reducido de características, siendo la forma de clasificar F_3 la que mejora más visiblemente, aumentando del 91,6 % de clasificación correcta al utilizar todas las variables, al 96 % empleando sólo las características seleccionadas por el Análisis Discriminante en el proceso de reducción de variables.

A continuación, las Tablas 8.9 a, b y c muestran los promedios de clasificación correcta de la Regresión Logística para todos los casos considerados. Se puede comprobar que la reducción de variables tiene un efecto variable según el caso, mejorando el desempeño algunas veces y empeorándolo en otras, aunque la variación no es significativa. Comparando las Tablas 8.7 y 8.9 se puede observar cómo, en la mayoría de los casos, el desempeño de la Regresión Logística supera al del Análisis Discriminante en cuanto a clasificación correcta, aunque esto será estudiado más detenidamente en una sección posterior.

Tabla 8.9a. Resumen de resultados de la Regresión Logística para todos los casos. Se presenta el porcentaje de clasificación correcta para los algoritmos empleando el conjunto original de variables, “Var. Ori.” y el conjunto reducido, “Var. Red.”, para las 4 formas de clasificación consideraras, F_{123} , F_1 , F_2 y F_3 .

	M1	M1 50 Hz	Alt	Alt 35Hz	Alt 50Hz	Alt 65Hz	M1 Red
Var. Ori. F_{123}	98,6%	99,4%	98,0%	99,8%	100,0%	99,8%	99,0%
Var. Red. F_{123}	98,4%	99,3%	99,3%	100,0%	100,0%	100,0%	98,7%
Var. Ori. F_1	99,4%	99,7%	99,6%	99,9%	100,0%	100,0%	99,5%
Var. Red. F_1	98,2%	99,7%	99,1%	100,0%	100,0%	100,0%	99,5%
Var. Ori. F_2	100,0%	99,2%	100,0%	100,0%	100,0%	100,0%	98,5%
Var. Red. F_2	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%	99,9%
Var. Ori. F_3	100,0%	99,0%	100,0%	100,0%	100,0%	100,0%	99,2%
Var. Red. F_3	100,0%	99,7%	100,0%	100,0%	100,0%	100,0%	98,9%

Tabla 8.9b. Resumen de resultados de la Regresión Logística para todos los casos. Se presenta el porcentaje de clasificación correcta para los algoritmos empleando el conjunto original de variables, “Var. Ori.” y el conjunto reducido, “Var. Red.”, para las 4 formas de clasificación consideraras, F_{123} , F_1 , F_2 y F_3 .

	M2	M2 65Hz	M2 50Hz	M2 35Hz	M2 Red	AB	AB35Hz
Var. Ori. F_{123}	77,8%	89,5%	81,3%	94,7%	86,9%	92,0%	95,4%
Var. Red. F_{123}	78,0%	91,4%	79,0%	85,1%	86,4%	93,3%	95,8%
Var. Ori. F_1	85,2%	93,6%	89,4%	97,7%	88,0%	92,0%	95,6%
Var. Red. F_1	83,5%	85,8%	87,5%	95,8%	90,2%	91,8%	95,4%
Var. Ori. F_2	93,3%	93,7%	91,2%	95,5%	87,9%	95,9%	94,9%
Var. Red. F_2	93,7%	94,8%	91,3%	96,5%	91,8%	96,2%	97,8%
Var. Ori. F_3	85,1%	92,7%	86,8%	96,8%	83,2%	92,8%	99,5%
Var. Red. F_3	84,7%	94,8%	86,9%	86,1%	90,4%	94,5%	98,5%

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

Tabla 8.9c. Resumen de resultados de la Regresión Logística para todos los casos. Se presenta el porcentaje de clasificación correcta para los algoritmos empleando el conjunto original de variables, “Var. Ori.” y el conjunto reducido, “Var. Red.”, para las 4 formas de clasificación consideradas, F_{123} , F_1 , F_2 y F_3 , la última columna muestra el promedio de todos los casos.

	AB50Hz	AB65Hz	SM	SM35Hz	SM50Hz	SM65Hz	Promedio
Var. Ori. F_{123}	88,4%	96,4%	85,5%	98,1%	88,4%	93,5%	93,2%
Var. Red. F_{123}	93,6%	96,9%	86,4%	98,5%	92,5%	95,2%	93,0%
Var. Ori. F_1	90,0%	95,4%	93,2%	98,7%	93,8%	99,7%	95,6%
Var. Red. F_1	93,1%	94,5%	89,7%	98,3%	95,1%	99,5%	94,9%
Var. Ori. F_2	96,2%	97,3%	92,8%	96,3%	87,8%	93,5%	95,7%
Var. Red. F_2	96,5%	98,2%	94,0%	95,2%	91,3%	95,0%	96,6%
Var. Ori. F_3	91,6%	99,5%	90,4%	98,0%	85,1%	99,7%	95,1%
Var. Red. F_3	96,0%	99,6%	90,9%	95,9%	77,1%	96,5%	94,1%

La última columna de la Tabla 8.9c presenta el promedio del porcentaje correcto de clasificación de todos los casos considerados. Podemos constatar que el desempeño del algoritmo empleando todas las variables originalmente propuestas es similar al obtenido sólo con el conjunto reducido de características. Con este algoritmo, la eficiencia en las formas de clasificación F_1 , F_2 y F_3 (ver Tabla 8.2), son bastante similares entre sí.

En la Tabla 8.10 se muestra cómo afectó el proceso de reducción de variables al desempeño de la Regresión Logística. Se calculó la diferencia en el porcentaje de clasificación correcta para todos los casos considerados con todas las variables y sólo con el grupo reducido, y se presentan el promedio, el máximo y el mínimo de esta diferencia para las cuatro formas de clasificar estudiadas. Se puede observar que el promedio de dichas diferencias de desempeño es unos escasos 0,24%, es decir, que aunque la reducción de variables a veces mejora el desempeño y en otras ocasiones lo empeora, el desempeño general del algoritmo al considerar todos los casos en estudio no varía de forma significativa.

Tabla 8.10. Resumen de las diferencias en el desempeño de la Regresión Logística al reducir el número de variables. Se presenta el promedio de las diferencias de desempeño antes y después de reducir las variables, el máximo aumento y la máxima disminución de desempeño tras la reducción de variables.

Diferencia en el desempeño de la Regresión Logística al reducir el número de características para las formas de clasificación:	Promedio	Máximo aumento	Máxima disminución
F_{123}	-0,2%	5,3%	-9,7%
F_1	-0,7%	3,1%	-7,7%
F_2	0,9%	3,9%	-1,1%
F_3	-0,9%	7,1%	-10,7%
	-0,24%	4,9%	-7,3%

8.5 Clasificación por medio de Red Neuronal.

En las siguientes secciones se describen los resultados de clasificación para el diagnóstico obtenidos con las Redes Neuronales.

Primeramente se explicará el esquema utilizado para realizar las pruebas experimentales tanto en las Redes Neuronales como en los ensambles de las mismas.

a) Redes Neuronales: a diferencia del Análisis Discriminante y de la Regresión Logística, el desempeño de las Redes Neuronales no está determinado por los conjuntos de entrenamiento y validación, sino que depende, además, de la división del conjunto de entrenamiento en entrenamiento propiamente dicho y grupo de prueba, además de la inicialización aleatoria de los pesos sinápticos de la red. Considerando esto, se realizaron 10 clasificaciones diferentes con cada grupo de entrenamiento y validación del esquema de validación cruzada. Es decir, para cada grupo de entrenamiento se entrena la Red Neuronal, se clasifica el grupo de validación, luego se reinicializa la Red Neuronal para ser nuevamente entrenada con el mismo grupo de ensayos pero partiendo de un conjunto de pesos sinápticos aleatorios diferentes, repitiéndose este proceso de entrenamiento y reinicialización 10 veces. Por consiguiente, se tienen 1000 clasificaciones diferentes hechas con las Redes Neuronales, a diferencia de los dos algoritmos anteriores donde sólo se realizaron 100 clasificaciones diferentes por cada caso.

b) Ensamble de redes neuronales: como se describió en la sección 4.3.7 se puede decir que un ensamble de redes neuronales promedia el resultado de varias Redes Neuronales para lograr un desempeño mejor que el promedio de las redes por separado. En este trabajo, se proponen dos formas de seleccionar las redes que serán utilizadas en el ensamble, por lo tanto se consideran dos ensambles diferentes:

a) Ensamble de 10 redes: utiliza las 10 redes neuronales que se generan para clasificar cada grupo de ensayos. Es decir, para cada conjunto de ensayos de entrenamiento y validación se entrenan 10 Redes Neuronales diferentes, las cuales se guardan para ser utilizadas por el Ensamble de 10 ANN.

b) Ensamble de 3 redes: en vez de utilizar las 10 redes neuronales generadas por conjunto de ensayos, se seleccionan solamente 3 de ellas para

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

formar este segundo ensamble. Para seleccionar estas 3 redes se considera el desempeño de las redes al clasificar el grupo de Prueba, el subconjunto de entrenamiento, que no modifica los pesos sinápticos pero sí decide cuándo detener el entrenamiento, y se eligen las 3 que mejor clasificaron este grupo de Prueba. Hay que recalcar que se eligen las 3 redes de acuerdo el grupo de Prueba, parte del conjunto de Entrenamiento, antes de evaluar el conjunto de Validación, por lo que las redes seleccionadas no son necesariamente las que mejor clasificaron el conjunto de Validación. La intención de proponer este segundo ensamble es el de obtener un algoritmo que sea más eficiente que las Redes Neuronales simples, y menos demandante computacionalmente hablando que el Ensamble de 10 ANN. Se espera que el desempeño de este ensamble más pequeño sea mejor que las Redes Neuronales simples y no muy inferiores al Ensamble de 10 ANN.

8.5.1 Optimización del número de neuronas en la capa oculta

Antes de entrenar una red neuronal hay que definir su estructura básica. En este trabajo se optó por utilizar la estructura más empleada en problemas de clasificación [ARO07], una red del tipo Perceptrón Multicapa con una capa oculta. En el siguiente paso hay que definir el número de neuronas en las diferentes capas. Este valor depende del conjunto de datos de entrada, por lo que se optimizó el número de neuronas en la capa oculta para cada uno de los 20 grupos de ensayos empleados en esta tesis.

Para optimizar el número de neuronas en la capa oculta, primero se estimó un rango para dicho valor. Por ejemplo, para el grupo de ensayos realizados al Motor 2 (M2), se supuso este rango de 8 a 42 neuronas. Seguidamente se entrenó una red con 8 neuronas (el valor inferior de este rango) en la capa oculta. Se utilizaron todos los ensayos del grupo para el entrenamiento, y luego se empleó la red para evaluar todos los ensayos obteniéndose un valor del porcentaje de clasificación correcta. Este proceso se repitió 100 veces y se guardó el promedio del desempeño de las 100 redes como la estimación del desempeño de la red con ese número de neuronas en la capa oculta. A continuación, se repitió el proceso variando el número de neuronas en la capa oculta dentro del rango previamente supuesto. En el ejemplo del grupo M2 se entrenó a la red 100 veces con 8 neuronas en la capa oculta, luego otras 100 veces con 9 neuronas en la capa oculta y así sucesivamente hasta 42 neuronas.

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

Para definir el número de neuronas, se graficaron los resultados y se eligió el valor a partir del cual no se observa un aumento significativo del desempeño de la red. Por ejemplo, en la Fig. 8.21 se presentan los resultados del proceso de optimización del grupo de ensayos M2. En función del número de neuronas en la capa oculta, se ha representado con un punto el valor promedio de la estimación del desempeño de la red. Con un círculo se ha representado el valor de promedio más y menos la desviación estándar. Se puede observar que la desviación estándar no fluctúa de forma significativa al aumentar el número de neuronas en la capa oculta. Además, el desempeño mejora al aumentar el número de neuronas hasta las 35 ó 37, a partir de donde se mantiene relativamente constante. Por lo que en este caso se eligió un valor de 37 neuronas para la capa oculta. La interpretación de la gráfica es un poco subjetiva pues se podría elegir un valor ligeramente diferente al no ser obvio el punto a partir del cual ya no se observa mejora en el desempeño. Es decir, no se espera que la red varíe sustancialmente su desempeño por tener un número de neuronas ligeramente diferente en su capa oculta. Sin embargo, sí que se observa, por ejemplo, una variación significativa del desempeño de la red al variar el número de neuronas en la capa oculta de 15 a 37 neuronas (ver Fig. 8. 23).




Figura 8.23 Resultados de la optimización del número de neuronas en la capa oculta. El punto muestra el promedio de 100 redes utilizando el valor de la abscisa como número de neuronas en la capa oculta. Los círculos muestran la desviación estándar de los resultados.

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

Esta optimización se realizó para los 20 grupos de ensayos considerados en este trabajo. Los resultados se presentan en la Tabla 8.10. Se observa que, en general, los grupos con un mayor número de ensayos emplearon redes con más neuronas. Por ejemplo, el grupo M2, que es el que tiene mayor cantidad de ensayos, también es el que necesitó más neuronas en la capa oculta. También se observa que los grupos con ensayos a diferentes frecuencias emplearon más neuronas que aquellos con ensayos obtenidos a una única frecuencia. Como se describió en el capítulo 7, el comportamiento de las variables puede ser diferente cuando los ensayos se realizan con alimentación a distintas frecuencias. Por ejemplo, con el Factor de Forma de los ensayos realizados con variador Siemens a 35 Hz (ver Fig. 7.31), se puede separar con Fallo Leve o Fallo Medio de los ensayos de Motor Sano o Barra Rota, sin embargo, esta misma característica calculada con los ensayos realizados con el mismo variador pero a 50 Hz (ver Fig. 7.36) no presenta capacidad para discriminar entre los ensayos de Motor Sano y los demás. Nótese que los grupos AB (todos los ensayos del Motor 2 con variador Allen Bradley) y M2 50 Hz (ensayos del Motor 2 a 50 Hz, con variador Allen Bradley, Siemens y alimentación de Red) tienen cantidades de ensayos similares. Sin embargo, el grupo AB necesitó 30 neuronas en su capa oculta, mientras que el M2 50 Hz solamente 22.

También se puede apreciar que los ensayos del Motor 1 necesitaron una menor cantidad de neuronas en la capa oculta que los ensayos del Motor 2. Esto se puede deber a que los ensayos del Motor 1, como se vio con los resultados del Análisis Discriminante y la Regresión Logística, son clasificados más fácilmente por lo que son suficientes redes más pequeñas.

A continuación se presentan los resultados de las Redes Neuronales, Ensamble de 10 ANN y Ensamble de 3 ANN. Siguiendo el esquema utilizado en los dos casos anteriores, primero se mostrará el desempeño de los algoritmos para los grupos de ensayos obtenidos con alimentación de Red, luego se presentaran algunos ejemplos de los resultados obtenidos con otras alimentaciones. Seguidamente se mostrará un resumen de los resultados obtenidos con las Redes Neuronales y con los ensambles para todos los casos.

En el Anexo 3 se muestran los resultados obtenidos para todos los casos considerados.

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

Tabla 8.11 Resumen de la optimización de neuronas en la capa oculta de las redes neuronales para cada grupo de ensayos.

Resultados de la optimización de neuronas en la capa oculta		
Motor	Grupo	Neuronas en la capa oculta
Motor 1	Red	12
	Alt	16
	Alt35	11
	Alt50	14
	Alt65	19
	50 HZ	15
	Todo	18
Motor 2	Red	19
	AB	30
	SM	30
	AB35	21
	AB50	21
	AB65	21
	SM35	21
	SM50	21
	SM65	21
	35 Hz	25
	50 HZ	22
	65 HZ	22
	Todo	37

8.5.2 Alimentación con red.

a) Motor 1

Como se vio con los dos algoritmos anteriores, el porcentaje de clasificación correcta ponderada es extremadamente alto. De hecho, tanto con el conjunto original de variables, como con el conjunto reducido de variables, el desempeño fue superior al 99% para las Redes Neuronales: Ensamblados de 10 ANN y Ensamble de 3 ANN para las cuatro formas de clasificación consideradas. En Fig. 8.24 se presentan los resultados para las Redes Neuronales considerando la forma de clasificación F_{123} . El algoritmo utilizando el conjunto original de variables obtuvo un porcentaje de clasificación correcta ponderada de 98,8 %, y al emplear el conjunto reducido de características el desempeño fue casi el mismo, de 98,7%, disminuyendo menos del 0,1%.

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

En la Fig. 8.25 se muestra el resultado del Ensamble de 10 ANN para la misma forma de clasificación. Tanto con todas las variables originalmente consideradas como con el conjunto reducido, el porcentaje de clasificación correcta fue superior al 99%. Como se ve en la figura, solamente en un par ocasiones no se consiguió una clasificación perfecta.

La Fig. 8.26 presenta los resultados del Ensamble de 3 ANN para las formas de clasificación F_1 , F_2 y F_3 . El desempeño del algoritmo para la primera forma de clasificación fue del 99,5% cuando se empleó el conjunto original de variables, y se mantuvo igual tras reducir la cantidad de características. Para la forma de clasificar F_2 , el porcentaje de clasificación correcta fue del 99,4, tanto para el conjunto original de características como para el reducido. Para la tercera forma de clasificación el desempeño del algoritmo fue del 99,3 % originalmente y del 99,5% al reducir el número de características.

Como puede verse en las tres figuras, sólo en algunos casos no se consiguió una clasificación perfecta tanto para las Redes Neuronales como para los Ensamblados.




Figura 8.24 Gráfico de caja y bigotes para los resultados de Redes Neuronales para el caso M1Red F_{123} .

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta:
estudio comparativo




Figura 8.25 Gráfico de caja y bigotes para los resultados de Ensamble de 10 ANN para el caso M1Red
 F_{123} .




Figura 8.26 Gráfico de caja y bigotes para los resultados de Ensamble de 3 ANN para los casos M1Red
 F_1 , F_2 y F_3 .

b) Motor 2

A diferencia de los ensayos efectuados con el Motor 1 alimentado con Red, que fueron fácilmente clasificados con muy altos porcentajes correctos por prácticamente todos los métodos comparados, los ensayos hechos al Motor 2 sí presentan una mayor dificultad a los algoritmos clasificadores. Así, ningún algoritmo superó el 96% de clasificación correcta, en promedio.

En la primera figura de esta sección, la 8.27, se muestran los resultados de las Redes Neuronales para la forma de clasificación F_{123} (ver Tabla 8.2). En este caso, al reducir el número de características, el desempeño del método aumento del 87,2% al 90,5 %, es decir, una mejora del 3,2 %. Además, se observa en la Fig. 8.27 que las peores clasificaciones hechas con el grupo reducido de variables son ligeramente mejores que las realizadas con todas las características.

La Fig. 8.28 muestra un gráfico de caja y bigotes de los resultados del Ensamble de 10 ANN, también para la forma de clasificación F_{123} , en la que se discrimina entre los 4 tipos de estado de fallo del motor. En este caso el Ensamble de 10 ANN mejoró su eficiencia promedio del 91,2 % al 94,4 %. Además, se observa en el gráfico que, salvo en un par de excepciones, al utilizar el conjunto reducido de variables los resultados del algoritmo van del 85 % al 100 % de clasificación correcta, sin embargo, los resultados del Ensamble de 10 ANN empleando todas las variables se extienden de algo menos del 75 % a la clasificación del 100%. Es decir, en este caso, la reducción del número de variables no sólo mejora el promedio de clasificación, sino que también comprime y eleva el rango en que se observan los resultados.

La tercera figura de este grupo, Fig. 8.29, expone los resultados del Ensamble de 3 ANN para las formas de clasificación F_1 , F_2 y F_3 . En estos casos, la reducción de variables también supuso una ligera mejora en el desempeño del algoritmo. Así, para la forma de clasificación F_1 , el porcentaje de clasificación correcta mejoró del 94,4% al 95,1 %. Para el caso F_2 , los resultados promedio fueron idénticos tanto antes como después de la disminución del número de variables. Para la tercera forma de clasificación, F_3 , el desempeño promedio fue un poco inferior que el obtenido con los otros dos casos, sin embargo, también se consiguió una pequeña mejora del desempeño al reducir el número de características del 92,3 % al 93,7 %.

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo




Figura 8.27 Gráfico de caja y bigotes para los resultados de Redes Neuronales para el caso M2Red F_{123} .




Figura 8.28 Gráfico de caja y bigotes para los resultados de Ensamble de 10 ANN para el caso M2Red

F_{123} .

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo




Figura 8.29 Gráfico de caja y bigotes para los resultados de Ensamble de 3 ANN para los casos M2Red F_1 , F_2 y F_3 .

8.5.3 Resumen con las diferentes combinaciones de alimentaciones consideradas.

En las siguientes secciones se exponen los resultados de tres grupos de ensayos para ejemplificar el desempeño de la Redes Neuronales y los Ensamblados. Se eligieron los siguientes grupos:

- todos los ensayos realizados al Motor 2, tanto con alimentación de Red como con variador,
- los ensayos obtenidos con el Motor 2 alimentado con el variador Allen Bradley a 35 Hz y
- todos los ensayos realizados al Motor 2 alimentado con el variador Siemens a 35 Hz, 50 Hz y 65 Hz

No se muestran más resultados obtenidos con el Motor 1 debido a que el desempeño de las Redes Neuronales y los Ensamblados con estos ensayos fueron muy buenos en todos los casos, siendo en todos superior al 99%.

a) Todos los ensayos del Motor 2

En esta sección se verán los resultados de las Redes Neuronales, Ensamble de 10 ANN y Ensamble de 3 ANN para el conjunto de todos los ensayos realizados al Motor 2 y con todos los tipos de alimentación considerados.

Primeramente, en la Fig. 8.30, se observan los resultados de las Redes Neuronales para la forma de clasificación F_{123} . Para este grupo de ensayos se observa que la reducción de variables tuvo como consecuencia una muy ligera disminución del porcentaje de clasificación correcta. Así, con todas las características originalmente propuestas se consiguió un desempeño promedio del 90,6 % y al reducir la cantidad de variables indicativas de fallo se clasificaron correctamente el 89,8% de los ensayos. Es decir, al reducir el número de características disminuyó en menos de 0,8% el desempeño del algoritmo. En la gráfica se puede apreciar que los resultados tienen una distribución muy semejante antes y después de la reducción de variables, a excepción de una mayor cantidad de resultados extremos en el caso del algoritmo empleando el conjunto reducido de variables.




Figura 8.30 Gráfico de caja y bigotes para los resultados de Redes Neuronales ANN para el caso M2 F_{123} .

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

La Fig. 8.31 muestra el desempeño del Ensamble de 10 ANN para las formas de clasificación F_1 , F_2 y F_3 . Para el caso F_1 , se observa que, con todas las características calculadas, se consiguió un desempeño del 96,1% y al reducir el número de variables el desempeño del algoritmo fue del 94,1%. Considerando la segunda forma de clasificación expuesta en la gráfica, F_2 , el desempeño inicial fue del 96,6% y al disminuir la cantidad de característica fue de 95,1%. Para la clasificación F_3 , se clasificaron correctamente el 97% de los ensayos con todas las características y con el conjunto reducido de variables indicativas de fallo el desempeño del clasificador fue del 94,5%. Además, en este último caso los resultados se dispersan en un rango más amplio luego de la disminución de la cantidad de variables.




Figura 8.31 Gráfico de caja y bigotes para los resultados de Ensamble de 10 ANN para los casos M2 F_1 , F_2 y F_3 .

En la última gráfica de esta sección, Fig. 8.32, se presentan los resultados del Ensamble de 3 ANN, también para los casos de clasificación F_1 , F_2 y F_3 . El desempeño de este ensamble es muy similar al obtenido con el ensamble de 10 ANN como se puede concluir comparando las Fig. 8.29 y 8.30. En este caso, para la clasificación tipo F_1 , el porcentaje de clasificación correcta fue del 95,9% antes de disminuir la cantidad de características y del 93,9% luego de la reducción. Considerando la clasificación tipo F_2 , el desempeño del algoritmo también disminuyó del 96,5 % al 94,9% después de aplicar

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

el procedimiento de reducción de variables. Para la tercera forma de clasificación, F_3 , también se experimentó un descenso del porcentaje de clasificación correcta del 96,6% al 94,4% al disminuir la cantidad de características. Es de recalcar que como el Ensamble con 10 ANN y el Ensamble con 3 ANN tuvieron un desempeño casi idéntico a pesar que el ensamble que sólo utiliza 3 redes neuronales es menos exigente en términos computacionales.

Recordando los resultados del análisis realizado en el capítulo 7, es necesario destacar que este es el grupo de ensayos *a priori* más difícil de clasificar. Como se resaltó en el capítulo anterior, muchas características tienen relaciones no lineales con el estado de fallo del motor y otras presentan relaciones complejas con el nivel de carga el motor. Además, este grupo mezcla características de ensayos obtenidos con dos alimentadores distintos, Allen Bradley y Siemens, a tres frecuencias diferentes, 35 Hz, 50 Hz y 65 Hz, además de alimentación de red, es decir, se consideran en un solo grupo ensayos realizados con 7 alimentaciones diferentes. Debido a esto, este puede ser considerado como el grupo más completo de clasificar.




Figura 8.32 Gráfico de caja y bigotes para los resultados de Ensamble de 3 ANN para los casos M2 F_1 , F_2 y F_3 .

b) Ensayos AB a 35 Hz

En esta sección se describen los resultados de las Redes Neuronales, Ensamble de 10 ANN y Ensamble de 3 ANN para el grupo de ensayos obtenidos con el Motor 2 alimentado con el variador Allen Bradley a 35 Hz. Como se verá en las siguientes Fig., para este caso, el proceso de disminución de variables no solamente no afecta negativamente al desempeño de los algoritmos, sino que inclusive lo mejora ligeramente.

En la primera figura de esta sección (Fig. 8.33), se presentan los resultados de las Redes Neuronales para clasificar a los ensayos en las 4 condiciones de fallo consideradas: Motor Sano, Fallo Leve, Fallo Medio y Barra Rota. Se observa que el promedio, así como el rango de resultados aumentan al disminuir el número de características. Así, el desempeño promedio fue del 94,2% con todas las variables indicativas de fallo, y de 95,7 % empleando sólo el conjunto reducido de características. Comparando esta gráfica con la Fig. 8.29, correspondiente al grupo de todos los ensayos del Motor 2, se observa los resultados del grupo AB35 están más dispersos pero presentan un promedio de clasificación correcta mayor.




Figura 8.33 Gráfico de caja y bigotes para los resultados de Res Neuronales para el caso AB35 F₁₂₃.

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

En la Fig. 8.34 se observa un gráfico de caja y bigotes con los resultados del Ensemble de 10 ANN para la forma de clasificación F_{123} . En este caso también se observa una mejora del desempeño del algoritmo al reducir la cantidad de variables indicativas de fallo. Así, con todas las características originalmente propuestas, el Ensemble de 10 ANN obtuvo una clasificación correcta ponderada del 96,8% y después de disminuir la cantidad de variables, el desempeño fue del 96,4%. Comparando las Fig. 8.33 y 8.34, se concluye que el Ensemble de 10 ANN obtiene un desempeño mejor que las Redes Neuronales tanto con el conjunto original de variables, como con el conjunto reducido de características.

La tercera Figura de esta sección (Fig. 8.35) presenta el desempeño del Ensemble de 3 ANN para las formas de clasificación F_1 , F_2 y F_3 . Para la primera forma de clasificación, F_1 , el desempeño del Ensemble de 3 ANN disminuye del 97,4% al 96,2% al reducir el número de características. Para la forma de clasificación F_2 , en cambio el porcentaje de clasificación correcta aumentó del 96,2% al 97,8%, un 1,6%. Para la tercera forma de clasificación, F_3 , el desempeño del algoritmo disminuye un 0,7% al reducir la cantidad de características, del 98,4 % al 97,7%.

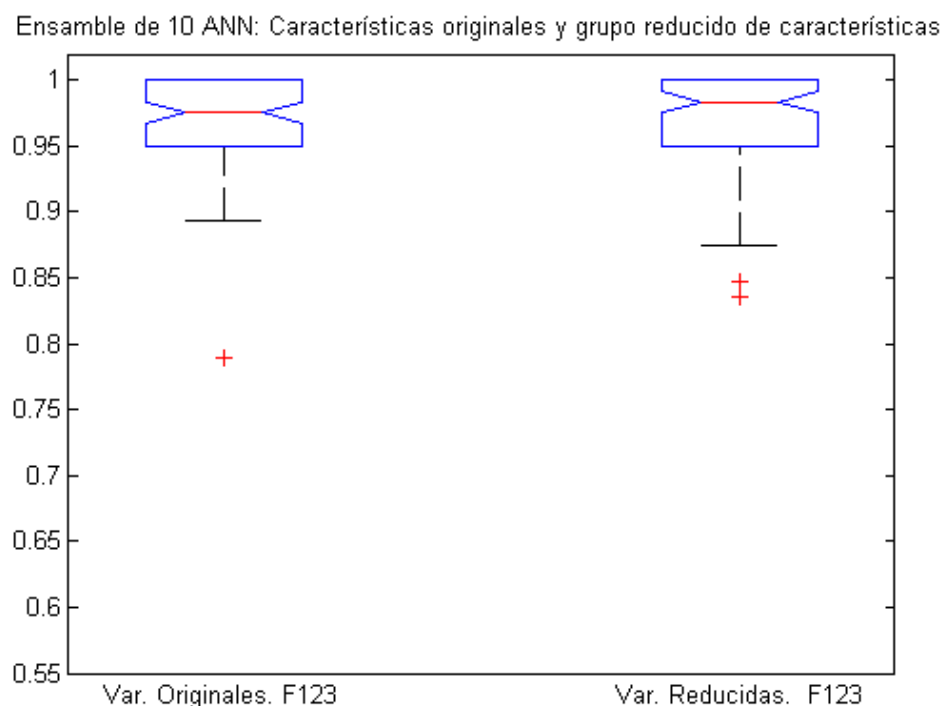


Figura 8.34 Gráfico de caja y bigotes para los resultados de Ensemble de 10 ANN para el caso AB35 F_{123} .

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo




Figura 8.35 Gráfico de caja y bigotes para los resultados de Ensamble de 3 ANN para los casos AB35 F₁, F₂ y F₃.

Es de resaltar el alto porcentaje de clasificación correcta obtenido por los tres algoritmos considerados en esta sección. En todos los casos se observó un desempeño superior al 94,2%.

c) Ensayos SM

En esta sección se presentan los resultados con el grupo de ensayos realizados al Motor 2 con alimentación de variador Siemens a las 3 frecuencias consideradas, 35 Hz, 50 Hz y 65 Hz. Es importante recalcar la dificultad que presenta para la clasificación correcta el hecho de asociar en un mismo grupo ensayos obtenidos a frecuencias diferentes, ya que vio en el capítulo 7 como algunas características tienen comportamientos diferentes a distintas frecuencias, dificultando la correcta clasificación.

En la Fig. 8.36 se observa un gráfico de caja y bigotes con los resultados de las Redes Neuronales para las formas de clasificación F₁, F₂ y F₃. Para la primera forma de clasificación F₁, el porcentaje de clasificación correcta aumenta del 96,4% al 97,4% al disminuir la cantidad de características. Con la segunda forma de clasificación considerada en la figura, el desempeño promedio de las Redes Neuronales con el conjunto original de variables fue del 94,3% y al emplear el conjunto reducido de

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

variables indicativas de fallo el porcentaje de clasificación correcta aumenta al 95,4%. Para la última forma de clasificación, en cambio la reducción de variables disminuye ligeramente el desempeño del método. Así, empleando el conjunto original de características, el porcentaje de clasificación correcta fue del 95,5% y al utilizar el conjunto reducido de variables, las Redes Neuronales clasificaron correctamente el 95,3%, es decir, solamente un 0,2% menos.

Las Fig. 8.37 y 8.38 presentan los resultados para los Ensamble de 10 ANN y Ensamble de 3 ANN respectivamente. En ambos casos se considera la forma de clasificación F_{123} , es decir, se discrimina entre las 4 clases de fallos.

El Ensamble de 10 ANN clasificó correctamente al 95,4% de los ensayos empleando todas las variables, y este desempeño subió al 96,1% al reducir la cantidad de características utilizadas.

El Ensamble de 3 ANN también mejoró su desempeño al emplear el conjunto reducido de características, así, utilizando todas las variables indicativas de fallo inicialmente propuestas, el algoritmo obtuvo un porcentaje de clasificación correcta del 94,7%, pero al reducir el número de características empleadas, el desempeño subió al 96,1%.




Figura 8.36 Gráfico de caja y bigotes para los resultados de Redes Neuronales para los casos SM F_1 , F_2 y F_3 .

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta:
estudio comparativo




Figura 8.37 Gráfico de caja y bigotes para los resultados de Ensamble de 10 ANN para el caso SM F_{123} .




Figura 8.38 Gráfico de caja y bigotes para los resultados de Ensamble de 3 ANN para los casos SM F_1 , F_2
y F_3 .

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

Comparando ambas figuras (Fig. 8.36 y 8.37), se observa el desempeño bastante parecido del Ensemble de 10 ANN con el Ensemble de 3 ANN. De hecho, el porcentaje de clasificación correcta de ambos algoritmos utilizando el conjunto reducido de características es el mismo, 96,1%. Esto indica, que al menos en este caso, el esquema para elegir 3 redes neuronales para formar el ensemble funciona correctamente, pues con menos de un tercio del esfuerzo computacional (en el clasificador) se obtiene el mismo resultado.

A continuación, la Tabla 8.12 muestra los promedios de clasificación correcta de las Redes Neuronales, Ensemble de 10 ANN y Ensemble de 3 ANN de los casos presentados en las secciones precedentes. Los resultados para todos los casos considerados se presentan en el Anexo 3. Como se puede observar en la Tabla 8.12, el desempeño de las Redes Neuronales es inferior al obtenido por el Ensemble de 10 ANN o el Ensemble de 3 ANN. Como se vio en las secciones previas, el proceso de reducción de variables, que siempre supone una reducción de la información suministrada a la red neuronal, no tiene un impacto negativo significativo sobre el desempeño de clasificación de las redes. Sin embargo, la eliminación de variables si supone una reducción del esfuerzo computacional. En la Tabla 8.13 se muestra cómo influye, en el desempeño de las Redes Neuronales, el proceso de reducción de variables. Similarmente a lo hecho con el Análisis Discriminante (Tabla 8.8), y con la Regresión Logística (Tabla 8.10), se calculó la diferencia entre el porcentaje de clasificación correcta del algoritmo empleando todas las variables, y dicho porcentaje para el algoritmo utilizando sólo el grupo reducido de características para todos los casos considerados. Se presentan el promedio, el máximo y el mínimo de esta diferencia para las cuatro formas de clasificar estudiadas. Se puede observar que el promedio de dichas diferencias de desempeño está alrededor del 0,6%. Esto indica que, considerando todos los casos, las Redes Neuronales tienen un mejor desempeño con el conjunto reducido de variables, a pesar de que, en algunas ocasiones, la reducción del número de variables empeora el desempeño del algoritmo. En otros casos, el método obtiene mejores resultados con el conjunto reducido de características. Además, la utilización de menos variables se traduce en una reducción del esfuerzo computacional requerido tanto por el algoritmo como para calcular las características.

Es de destacar que la variación del desempeño de las Redes Neuronales al reducir la cantidad de variables en ningún caso fue significativa. La Tabla 8.13 nos indica que la

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

mayor disminución fue de sólo el 2 % y el mayor aumento del desempeño fue menor al 4%.

Tabla 8.12 Resumen de resultados de las Redes Neuronales, Ensamble de 10 ANN y Ensamble de 3 ANN para los casos presentados en este capítulo. Se presenta el porcentaje de clasificación correcta para los algoritmos empleando el conjunto original de variables (“Var. Ori.”) y el conjunto reducido (“Var. Red.”), para las 4 formas de clasificación consideraras, F_{123} , F_1 , F_2 y F_3 .

		M1 Red	M2 Red	M2	AB35Hz	SM
Redes Neuronales	Var. Ori. F_{123}	98,8%	87,2%	90,6%	94,2%	93,1%
Redes Neuronales	Var. Red. F_{123}	98,7%	90,5%	89,8%	95,7%	95,2%
Redes Neuronales	Var. Ori. F_1	99,4%	91,2%	94,9%	96,2%	96,4%
Redes Neuronales	Var. Red. F_1	99,5%	93,1%	92,9%	96,4%	97,7%
Redes Neuronales	Var. Ori. F_2	99,0%	92,1%	95,6%	95,4%	94,3%
Redes Neuronales	Var. Red. F_2	99,2%	93,3%	94,6%	96,8%	95,4%
Redes Neuronales	Var. Ori. F_3	99,0%	87,6%	95,0%	97,4%	95,5%
Redes Neuronales	Var. Red. F_3	99,2%	91,1%	93,0%	97,6%	95,3%
Ensamble de 10 ANN	Var. Ori. F_{123}	99,2%	91,2%	93,0%	96,1%	94,7%
Ensamble de 10 ANN	Var. Red. F_{123}	99,4%	93,2%	91,7%	96,4%	96,1%
Ensamble de 10 ANN	Var. Ori. F_1	99,5%	94,4%	95,9%	97,4%	97,6%
Ensamble de 10 ANN	Var. Red. F_1	99,5%	95,1%	93,9%	96,7%	98,5%
Ensamble de 10 ANN	Var. Ori. F_2	99,4%	94,4%	96,5%	96,2%	95,2%
Ensamble de 10 ANN	Var. Red. F_2	99,4%	95,1%	94,9%	97,8%	95,8%
Ensamble de 10 ANN	Var. Ori. F_3	99,3%	92,3%	96,6%	98,4%	97,0%
Ensamble de 10 ANN	Var. Red. F_3	99,5%	93,7%	94,4%	97,7%	96,8%
Ensamble de 3 ANN	Var. Ori. F_{123}	99,3%	91,2%	93,6%	96,6%	95,4%
Ensamble de 3 ANN	Var. Red. F_{123}	99,2%	94,4%	92,1%	96,8%	96,1%
Ensamble de 3 ANN	Var. Ori. F_1	99,5%	95,0%	96,1%	98,0%	97,9%
Ensamble de 3 ANN	Var. Red. F_1	99,5%	95,9%	94,1%	97,1%	98,6%
Ensamble de 3 ANN	Var. Ori. F_2	99,3%	94,6%	96,6%	96,4%	95,6%
Ensamble de 3 ANN	Var. Red. F_2	99,5%	95,9%	95,1%	97,6%	96,0%
Ensamble de 3 ANN	Var. Ori. F_3	99,3%	92,6%	97,0%	98,4%	97,2%
Ensamble de 3 ANN	Var. Red. F_3	99,6%	94,5%	94,5%	97,6%	97,1%

Tabla 8.13 Resumen de las diferencias en el desempeño de las Redes Neuronales al reducir el número de variables. Se presenta el promedio de las diferencias de desempeño antes y después de reducir las variables, el máximo aumento y la máxima disminución de desempeño tras la reducción de variables

Diferencia en el desempeño de las Redes Neuronales al reducir el número de características para las formas de clasificación:	Promedio	Máximo aumento	Máxima disminución
F_{123}	1,2%	3,9%	-0,7%
F_1	0,3%	3,8%	-2,0%
F_2	0,6%	2,8%	-1,1%
F_3	0,5%	3,5%	-1,9%
	0,6%	3,5%	-1,5%

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

La Tabla 8.14 presenta un resumen del efecto de la reducción de variables en el desempeño del Ensamble de 10 ANN. No se aprecia una variación significativa del porcentaje de clasificación correcta del algoritmo al emplear todas las variables o sólo el conjunto reducido, pues esta diferencia es de únicamente el 0,1% como se ve en la Tabla 8.14.

Finalmente, la Tabla 8.15 muestra el mismo resultado que las dos anteriores pero para el algoritmo Ensamble de 3 ANN. Comparando las Tablas 8.12, 8.13 y 8.14 se observa como el desempeño del Ensamble de 10 ANN y del Ensamble de 3 ANN son bastante similares. Además, el desempeño de los ensambles varía menos con la reducción de variables que las Redes Neuronales.

Tabla 8.14 Resumen de las diferencias en el desempeño del Ensamble de 10 ANN al reducir el número de variables. Se presenta el promedio de las diferencias de desempeño antes y después de reducir las variables, el máximo aumento y la máxima disminución de desempeño tras la reducción de variables

Diferencia en el desempeño de las Redes Neuronales al reducir el número de características para las formas de clasificación:	Promedio	Máximo aumento	Máxima disminución
F ₁₂₃	0,3%	2,1%	-1,8%
F ₁	0,0%	3,0%	-2,0%
F ₂	0,4%	2,4%	-1,6%
F ₃	-0,2%	1,5%	-2,5%
	0,1%	2,3%	-1,9%

Tabla 8.15 Resumen de las diferencias en el desempeño del Ensamble de 3 ANN al reducir el número de variables. Se presenta el promedio de las diferencias de desempeño antes y después de reducir las variables, el máximo aumento y la máxima disminución de desempeño tras la reducción de variables.

Diferencia en el desempeño del Ensamble de 3 ANN al reducir el número de características para las formas de clasificación:	Promedio	Máximo aumento	Máxima disminución
F ₁₂₃	0,3%	3,2%	-1,5%
F ₁	-0,1%	2,6%	-2,1%
F ₂	0,3%	2,0%	-1,6%
F ₃	-0,3%	1,9%	-3,0%
	0,1%	2,4%	-2,0%

8.6 Comparación de los clasificadores considerados.

En esta sección se compara el desempeño de los 5 algoritmos considerados en esta tesis. Las secciones previas se enfocaron en mostrar el desempeño de los métodos de clasificación de forma individual y en analizar el efecto de la reducción de variables en los mismos. La reducción de variables fue beneficiosa para el desempeño del Análisis Discriminante, salvo algunas pocas excepciones. Para los otros algoritmos, la reducción

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

de variables no alteró significativamente el desempeño de los mismos, pues considerando el promedio de todos los casos, tanto la Regresión Logística como los métodos basados en Redes Neuronales obtuvieron porcentajes de clasificación correcta similares al emplear el conjunto original de variables y el conjunto reducido de características. Considerando esto, en adelante se comparará el desempeño de los algoritmos en base a su porcentaje de clasificación correcta empleando el conjunto reducido de características.

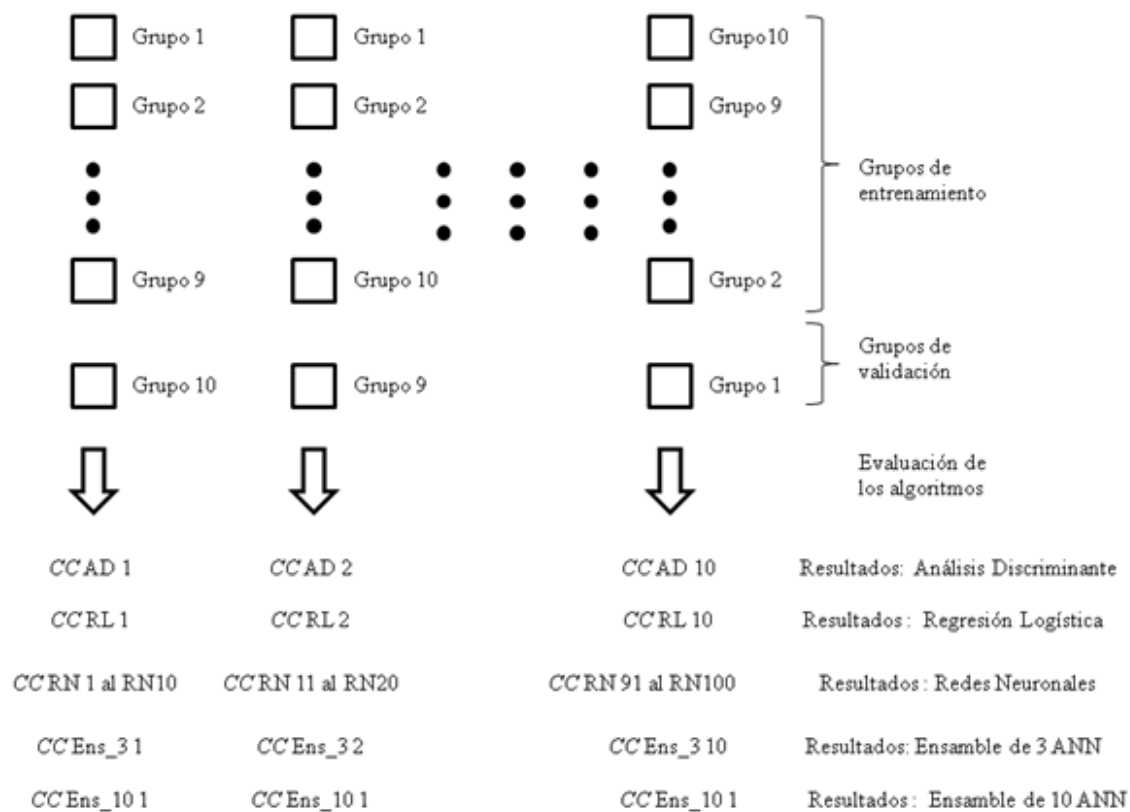


Figura 8.39 Esquema de evaluación de los algoritmos. CC es el porcentaje de clasificación correcta ponderada ecuación (6.14).

Tabla 8.16 Ejemplo de resultados obtenidos con el Análisis Discriminante y Regresión Logística para una aplicación del esquema de validación cruzada de 10 iteraciones.

Ejemplo de resultados obtenidos con el Análisis Discriminante y la Regresión Logística										
Iteración número	1	2	3	4	5	6	7	8	9	10
Análisis Discriminante	90%	91%	90%	93%	89%	90%	94%	88%	92%	91%
Regresión Logística	89%	91%	90%	93%	92%	93%	94%	92%	92%	91%

Cabe recordar que la división de ensayos para formar los grupos de entrenamiento y validación se realizó previamente a la aplicación de los algoritmos, y se emplearon los

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

mismos conjuntos con sus divisiones, en el mismo orden para todos los algoritmos. Como se observa en la Fig. 8.39, la división de los grupos de ensayos utilizados para entrenar y validar los algoritmos es la misma para todos ellos. Así, el primer resultado del Análisis Discriminante utilizó el grupo 10 como grupo de validación, al igual que la Regresión Logística, Ensamble de 3 ANN y Ensamble de 10 ANN.

La Tabla 8.16 presenta un ejemplo de los resultados obtenidos por el Análisis Discriminante y la Regresión Logística. En este ejemplo se observa que, de las 10 iteraciones o clasificaciones hechas por ambos métodos con el esquema de validación cruzada, en una ocasión, la primera iteración, el Análisis Discriminante obtuvo un rendimiento superior al alcanzado por la Regresión Logística. En esta primera iteración, el Análisis Discriminante obtuvo un 90% de clasificación correcta ponderada mientras que la Regresión Logística un 89%. En esta iteración ambos algoritmos emplearon los mismos ensayos como grupo de entrenamiento y el grupo de validación clasificado fue el mismo para ambos métodos. En las siguientes iteraciones se observa que la Regresión Logística fue mejor en 3 ocasiones y ambos algoritmos obtuvieron el mismo porcentaje de clasificación correcta ponderada en 6 iteraciones. En resumen, en el ejemplo, el Análisis Discriminante fue mejor en 1 ocasión, la Regresión Logística en 3 y ambos algoritmos tuvieron el mismo rendimiento en 6 iteraciones. Este mismo análisis se realiza para cada par de algoritmos. Al momento de comparar un algoritmo con las Redes Neuronales simples hay que recordar que las mismas realizan 10 clasificaciones por grupo de validación en vez de una, es decir, 100 clasificaciones por implementación del esquema de validación cruzada.

Este análisis permite poder comparar el resultado de los algoritmos utilizando los mismos ensayos para entrenamiento y validación, por lo que al comparar dos algoritmos se puede calcular la diferencia promedio entre sus resultados y mostrar en cuántos casos uno fue mejor que el otro y en cuanto tuvieron el mismo desempeño.

8.6.1 Alimentación con red.

Primeramente se comparan los algoritmos empleando los ensayos obtenidos con alimentación de Red, tanto con el Motor 1 como con el Motor 2.

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

a) Motor 1

Como se vio en las secciones previas, los ensayos realizados con el Motor 1 fueron clasificados correctamente con muy altos porcentajes por todos los algoritmos, por lo que no se aprecian diferencias significativas entre ellos.

La Fig. 8.40 muestra los resultados de los 5 algoritmos para los ensayos de este grupo, considerando la forma de clasificación F_{123} (ver Tabla 8.2). Se puede apreciar, que salvo algunos casos aislados, todos los algoritmos realizaron una clasificación perfecta.

Comparación de Análisis Discriminante, Regresión Logística, Redes Neuronales y Ensamblés.




Figura 8.40 Gráfico de caja y bigotes para los resultados de todos los algoritmos considerados para el caso M1Red F_{123} .

En la Tabla 8.17 se presenta una comparación de los resultados obtenidos por los 5 algoritmos. Se realizó una comparación uno a uno, donde se calculó la diferencia en desempeño en cada clasificación hecha por los algoritmos con los mismos datos. Se anotó también la cantidad de veces que los algoritmos obtuvieron el mismo desempeño con los mismos ensayos, y cuantas veces fue mejor cada algoritmo. En la tabla se especifican dos algoritmos a comparar, denominados algoritmo A y algoritmo B, así, en la primera fila se compara a la Regresión Logística (algoritmo A) con el Análisis Discriminante (algoritmo B). La tercera columna muestra la diferencia entre el porcentaje de clasificación correcta del algoritmo A y el algoritmo B, (para la primera

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta:
estudio comparativo

fila es la diferencia entre el desempeño de la Regresión Logística y el Análisis Discriminante). La cuarta columna de la Tabla 8.17 indica en cuantas clasificaciones de las 100 (1000 en el caso de las Redes Neuronales) los dos algoritmos comparados en cada fila tuvieron el mismo porcentaje de clasificación correcta. Así, en la primera fila se muestra que en 81 ocasiones la Regresión Logística y el Análisis Discriminante tuvieron el mismo desempeño. La quinta columna presenta la cantidad de veces en que el algoritmo A tuvo un desempeño mejor que el algoritmo B, y la última columna muestra cuantas veces el algoritmo B obtuvo un mejor resultado. Así, en la primera fila vemos que en ninguna ocasión la Regresión Logística fue mejor que el Análisis Discriminante pero el Análisis Discriminante tuvo un mejor desempeño en 19 clasificaciones.

Examinando la Tabla 8.17 se observa que, en la gran mayoría de casos, los algoritmos tuvieron el mismo desempeño. Por ejemplo, la Regresión Logística y el Análisis Discriminante tuvieron el mismo porcentaje de clasificación correcta en 81 ocasiones y en 19 fue mejor el Análisis Discriminante, siendo el Análisis Discriminante mejor en un 1,26%. Se ve también, que en este caso, el Ensamble de 3 ANN tuvo un mejor desempeño que el Ensamble de 10 ANN, aún esta diferencia es de solo 0,18% y se debe a las 3 únicas ocasiones en que no tuvieron el mismo desempeño.

Tabla 8.17 Resumen de las diferencias en el desempeño entre los algoritmos considerados para la clasificación F_{123} y el grupo de ensayos M1Red. Se calcula, para cada clasificación, la diferencia entre el desempeño del algoritmo A y el B y se muestra el promedio, la cantidad de veces que tuvieron el mismo porcentaje de clasificación correcta, cuantas veces el algoritmo A fue mejor y cuantas lo fue el algoritmo B.

Algoritmo A	Algoritmo B	Promedio de la diferencia de A- B	Igual desempeño	A fue mejor	B fue mejor
Regresión L.	Análisis D.	-1,26%	81	0	19
Redes N.	Análisis D.	-1,29%	854	0	146
Redes N.	Regresión L.	-0,02%	846	99	55
Ensamble 3	Redes N.	0,64%	891	83	26
Ensamble 10	Redes N.	0,46%	887	74	39
Ensamble 3	Análisis D.	-0,65%	92	0	8
Ensamble 10	Análisis D.	-0,82%	89	0	11
Ensamble 3	Regresión L.	0,62%	88	12	0
Ensamble 10	Regresión L.	0,44%	90	10	0
Ensamble 10	Ensamble 3	-0,18%	97	0	3

b) Motor 2

La Fig. 8.41 presenta los resultados de los 5 algoritmos considerados para el grupo de ensayos obtenidos con el Motor 2 alimentado de Red. En la misma se puede apreciar como el Análisis Discriminante presenta el desempeño más bajo de los 5 algoritmos. La Regresión Logística mejora los resultados del Análisis Discriminante y las Redes Neuronales a su vez presentan un desempeño más elevado que la Regresión Logística. Finalmente, el Ensamble de 10 ANN muestra los mejores resultados obtenidos, aunque la diferencia con el Ensamble de 3 ANN es exigua.

Comparación de Análisis Discriminante, Regresión Logística, Redes Neuronales y Ensamblados.




Figura 8.41 Gráfico de caja y bigotes para los resultados de todos los algoritmos considerados para el caso M2 Red F₁₂₃.

La Tabla 8.18 presenta los resultados de la comparación uno a uno de los algoritmos de forma similar a la expuesta en la Tabla 8.17. También se observa que el Análisis Discriminante tuvo el peor desempeño de los algoritmos estudiados. Comparándolo con las Redes Neuronales, las redes fueron, en promedio, un 5,85% superior en cuanto al porcentaje de clasificación correcta. También se observa que, de las 1000 clasificaciones hechas por las Redes Neuronales, 736 tuvieron un desempeño superior al Análisis Discriminante cuando utilizaron el mismo conjunto de ensayos de entrenamiento y validación. Por otro lado, en solo 261 ocasiones el Análisis Discriminante consiguió una mejor clasificación. La mayor diferencia se observa entre el Ensamble de 10 ANN y el Análisis Discriminante, donde el Ensamble de 10 ANN

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

obtuvo una clasificación correcta un 9,79% superior en promedio. Finalmente, cabe resaltar que la menor diferencia está entre el Ensamble de 10 ANN y el Ensamble de 3 ANN, donde el Ensamble de 10 ANN es superior en un 1,22%, pero en 52 de las clasificaciones hechas ambos obtuvieron el mismo porcentaje de clasificación correcta.

Tabla 8.18 Resumen de diferencia del desempeño entre los algoritmos considerados para la clasificación F_{123} y el grupo de ensayos M1Red. Se calcula, para cada clasificación, la diferencia entre el desempeño del algoritmo A y el B y se muestra el promedio, la cantidad de veces que tuvieron el mismo porcentaje de clasificación correcta, cuantas veces el algoritmo A fue mejor y cuantas lo fue el algoritmo B.

Algoritmo A	Algoritmo B	Promedio de la diferencia de A- B	Igual desempeño	A fue mejor	B fue mejor
Regresión L.	Análisis D.	1,73%	1	61	38
Redes N.	Análisis D.	5,83%	3	736	261
Redes N.	Regresión L.	4,10%	23	651	326
Ensamble 3	Redes N.	2,72%	170	591	239
Ensamble 10	Redes N.	3,95%	196	660	144
Ensamble 3	Análisis D.	8,55%	1	82	17
Ensamble 10	Análisis D.	9,78%	0	87	13
Ensamble 3	Regresión L.	6,83%	0	75	25
Ensamble 10	Regresión L.	8,05%	2	84	14
Ensamble 10	Ensamble 3	1,22%	52	34	14

8.6.2 Alimentación con Siemens a 65 Hz

En esta sección se comparan los resultados de los 5 algoritmos estudiados para el grupo de ensayos obtenidos con el Motor 2 alimentado con variador Siemens a 65 Hz La Fig. 8.42 presenta los resultados de los algoritmos para la forma de clasificación F_{123} .

La Figura 8.43 muestra el desempeño de los clasificadores para la forma de clasificar F_1 , es decir, discriminan solamente entre Motor Sano y motor con fallo de cualquier severidad. Comparando esta gráfica con la 8.42 se observa como con esta forma de clasificación se logra un desempeño mucho más elevado. Evidentemente en este caso es sencillo discriminar entre motor Sano y no sano, lo que aparentemente es más complicado es diagnosticar la severidad del fallo

La Tabla 8.19 expone los resultados de comparar los algoritmos para la forma de clasificación F_{123} . En ella se aprecia un orden de eficiencia de los algoritmos similar al obtenido con el caso M2Red, es decir, el Análisis Discriminante fue el que mostró un desempeño más pobre entre los 5 algoritmos. La Regresión Logística superó al Análisis Discriminante por un 2,18% pero fue inferior a las Redes Neuronales por un 1,44% y al

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

Ensamble de 3 ANN por un 2,18%. El Ensamble de 10 ANN fue el de mejor desempeño, superando a las Redes Neuronales por 1,1% y al Ensamble de 3 ANN por 0,35%. Cabe resaltar que, además de ser pequeña la diferencia entre el Ensamble de 10 ANN y el Ensamble de 3 ANN, en 80 de las 100 clasificaciones que realizaron obtuvieron el mismo porcentaje de clasificación correcta.

La Tabla 8.20 muestra la comparación de los algoritmos para la forma de clasificación F_1 . Como se observa en la Fig. 8.40, todos los algoritmos clasificaron correctamente la gran mayoría de los ensayos, por lo que las diferencias entre los mismos no son significativas. Como se aprecia en la columna que señala la cantidad de veces que los métodos obtuvieron el mismo desempeño, cuarta columna de la tabla, los algoritmos comparados tuvieron el mismo desempeño en más del 88% de las clasificaciones.

Comparación de Análisis Discriminante, Regresión Logística, Redes Neuronales y Ensamblados.




Figura 8.42 Gráfico de caja y bigotes para los resultados de todos los algoritmos considerados para el caso SM65 F_{123} .

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

Comparación de Análisis Discriminante, Regresión Logística, Redes Neuronales y Ensamblados.




Figura 8.43 Gráfico de caja y bigotes para los resultados de todos los algoritmos considerados para el caso SM65 F₁.

Tabla 8.19 Resumen de las diferencias en el desempeño entre los algoritmos considerados para la clasificación F₁₂₃ y el grupo de ensayos SM 65. Se calcula, para cada clasificación, la diferencia entre desempeño del algoritmo A y el B y se muestra el promedio, la cantidad de veces que tuvieron el mismo porcentaje de clasificación correcta, cuantas veces el algoritmo A fue mejor y cuantas lo fue el algoritmo B.

Algoritmo A	Algoritmo B	Promedio de la diferencia de A- B	Igual desempeño	A fue mejor	B fue mejor
Regresión L.	Análisis D.	2,18%	29	53	18
Redes N.	Análisis D.	3,62%	286	627	87
Redes N.	Regresión L.	1,44%	384	400	216
Ensamble 3	Redes N.	0,75%	601	265	134
Ensamble 10	Redes N.	1,10%	628	278	94
Ensamble 3	Análisis D.	4,36%	30	66	4
Ensamble 10	Análisis D.	4,71%	30	69	1
Ensamble 3	Regresión L.	2,18%	43	44	13
Ensamble 10	Regresión L.	2,53%	45	47	8
Ensamble 10	Ensamble 3	0,35%	80	13	7

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

Tabla 8.20 Resumen de las diferencias en el desempeño entre los algoritmos considerados para la clasificación F_1 y el grupo de ensayos SM 65. Se calcula, para cada clasificación, la diferencia entre desempeño del algoritmo A y el B y se muestra el promedio, la cantidad de veces que tuvieron el mismo porcentaje de clasificación correcta, cuantas veces el algoritmo A fue mejor y cuantas lo fue el algoritmo B.

Algoritmo A	Algoritmo B	Promedio de la diferencia de A - B	Igual desempeño	A fue mejor	B fue mejor
Regresión L.	Análisis D.	-0,31%	88	2	10
Redes N.	Análisis D.	-0,30%	885	20	95
Redes N.	Regresión L.	0,01%	885	57	58
Ensamble 3	Redes N.	0,18%	892	75	33
Ensamble 10	Redes N.	0,44%	901	99	0
Ensamble 3	Análisis D.	-0,13%	92	2	6
Ensamble 10	Análisis D.	0,14%	98	2	0
Ensamble 3	Regresión L.	0,19%	94	5	1
Ensamble 10	Regresión L.	0,45%	90	10	0
Ensamble 10	Ensamble 3	0,26%	94	6	0

8.6.3 Alimentación con Allen Bradley.

En esta sección se comparan los algoritmos con el grupo de ensayos realizados al Motor 2 con el alimentador Allen Bradley a 35 Hz, 50 Hz y 65 Hz A diferencia del caso anterior, este grupo presenta ensayos obtenidos a frecuencias diferentes, lo que *a priori* nos sugiere que podría ser más difícil de clasificar para los algoritmos estudiados. La Figura 8.44 presenta el desempeño de los 5 algoritmos para la forma de clasificar F_{123} . La Figura 8.45 hace lo mismo con la forma de clasificación F_2 .

La Tabla 8.21 muestra la comparación de los algoritmos empleados para la forma de clasificación F_{123} . De la observación de la Figura 8.44 y de esta Tabla se aprecia que otra vez el Análisis Discriminante mostró el peor desempeño de los 5 algoritmos. La Regresión Logística y las Redes Neuronales tienen un desempeño bastante parecido, aunque en este caso, la Regresión Logística tiene un desempeño un 0,21% mejor. La Fig. 8.44 nos muestra que las Redes Neuronales realizaron varias clasificaciones con un desempeño bastante más bajo que el resto, estas clasificaciones podrían ser la razón del mejor desempeño en promedio de la Regresión Logística.

La Tabla 8.22 presenta la comparación de los métodos para la forma de clasificación F_2 . Esta tabla, así como la Fig. 8.45, nos muestra que, en este caso, el desempeño del Análisis Discriminante fue muy similar, aunque un 0,05% mejor, que el desempeño de la Regresión Logística. Así, el Análisis Discriminante obtuvo un mejor porcentaje de

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

clasificación en 48 ocasiones y la Regresión Logística en 40. También se observa que las Redes Neuronales obtuvieron mejores resultados que los dos métodos estadísticos, obteniendo las Redes Neuronales un porcentaje de clasificación correcta un 0,59 % mayor que el Análisis Discriminante y un 0,63% mejor que la Regresión Logística.

Comparación de Análisis Discriminante, Regresión Logística, Redes Neuronales y Ensamblados.




Figura 8.44 Gráfico de caja y bigotes para los resultados de todos los algoritmos considerados para el caso AB F_{123} .

Tabla 8.21 Resumen de las diferencias en el desempeño entre los algoritmos considerados para la clasificación F_{123} y el grupo de ensayos AB. Se calcula, para cada clasificación, la diferencia entre desempeño del algoritmo A y el B y se muestra el promedio, la cantidad de veces que tuvieron el mismo porcentaje de clasificación correcta, cuantas veces el algoritmo A fue mejor y cuantas lo fue el algoritmo B.

Algoritmo A	Algoritmo B	Promedio de la diferencia de A- B	Igual desempeño	A fue mejor	B fue mejor
Regresión L.	Análisis D.	2,84%	0	84	16
Redes N.	Análisis D.	2,63%	1	775	224
Redes N.	Regresión L.	-0,21%	20	466	514
Ensamble 3	Redes N.	1,16%	46	633	321
Ensamble 10	Redes N.	1,79%	55	718	227
Ensamble 3	Análisis D.	3,79%	0	87	13
Ensamble 10	Análisis D.	4,42%	0	90	10
Ensamble 3	Regresión L.	0,94%	3	63	34
Ensamble 10	Regresión L.	1,58%	5	69	26
Ensamble 10	Ensamble 3	0,63%	29	49	22

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

Comparación de Análisis Discriminante, Regresión Logística, Redes Neuronales y Ensamblados.




Figura 8.45 Gráfico de caja y bigotes para los resultados de todos los algoritmos considerados para el caso AB F₂.

Tabla 8.22 Resumen de las diferencias en el desempeño entre los algoritmos considerados para la clasificación F₂ y el grupo de ensayos AB. Se calcula, para cada clasificación, la diferencia entre desempeño del algoritmo A y el B y se muestra el promedio, la cantidad de veces que tuvieron el mismo porcentaje de clasificación correcta, cuantas veces el algoritmo A fue mejor y cuantas lo fue el algoritmo B.

Algoritmo A	Algoritmo B	Promedio de la diferencia de A- B	Igual desempeño	A fue mejor	B fue mejor
Regresión L.	Análisis D.	-0,05%	12	40	48
Redes N.	Análisis D.	0,59%	65	548	387
Redes N.	Regresión L.	0,63%	185	496	319
Ensamble 3	Redes N.	0,60%	305	462	233
Ensamble 10	Redes N.	0,73%	320	467	213
Ensamble 3	Análisis D.	1,19%	7	65	28
Ensamble 10	Análisis D.	1,32%	7	66	27
Ensamble 3	Regresión L.	1,23%	21	54	25
Ensamble 10	Regresión L.	1,36%	22	58	20
Ensamble 10	Ensamble 3	0,13%	55	26	19

Los ensambles, tanto de 10 redes como de 3, obtuvieron un desempeño mejor que los otros tres algoritmos. El Ensamble de 10 ANN fue ligeramente mejor, un 0,13%, mejor que el Ensamble de 3 ANN, aunque en más de la mitad de los casos tuvieron el mismo desempeño.

8.6.4 Motor 2 con alimentación a 35 Hz

En esta sección se compara el desempeño de los clasificadores utilizando los ensayos obtenidos con el Motor 2 alimentado con los variadores Allen Bradley y Siemens a 35 Hz. En este caso todos los ensayos fueron realizados a la misma frecuencia pero con dos variadores diferentes. Como se vio en el capítulo 7, algunas características, sobre todo estadísticas, tienen un comportamiento diferente según el alimentador, representando esto una dificultad particular a los algoritmos.

La Fig. 8.46 presenta el desempeño de los 5 métodos para la forma de clasificación F_{123} . La Fig. 8.47 muestra los resultados de los algoritmos para la forma de clasificación F_3 , esta es la forma de clasificación que discrimina únicamente entre motor con Barra Rota o no.

La Tabla 8.23 presenta la comparación entre los algoritmos para la forma de clasificación F_{123} . Del análisis de esta Tabla y de la Fig. 8.46 se concluye que el desempeño de los dos métodos estadísticos es visiblemente inferior a los basados en Redes Neuronales. Entre los algoritmos estadísticos, la Regresión Logística mostró un desempeño un 1.34% mejor que el Análisis Discriminante pero más de un 9% inferior a las Redes Neuronales.

En este caso, nuevamente el Ensamble de 10 ANN y el Ensamble de 3 ANN tuvieron mejor desempeño que las Redes Neuronales, un 1,9 % y 1,41% respectivamente. Comparando ambos tipos de ensambles se observa que el Ensamble de 10 ANN obtuvo mejores resultados que el Ensamble de 3 ANN, aunque por menos del 0,5%.

En la Tabla 8.24 se expone la comparación de los clasificadores para la forma de clasificación F_3 . Los resultados mostrados indican que, en este caso, también el Ensamble de 10 ANN fue el que consiguió el mejor desempeño, aunque por un margen muy pequeño sobre el Ensamble de 3 ANN. Las Redes Neuronales tuvieron un desempeño un 0,72% y 1,49% inferior al Ensamble de 3 ANN y Ensamble de 10 ANN respectivamente. Los tres algoritmos basados en Redes Neuronales fueron claramente superiores a los métodos estadísticos, por 9,78 % o más. A diferencia de cuando se consideró la forma de clasificación F_{123} , en este caso fue el Análisis Discriminante el que presentó mejores resultados, superando a la Regresión Logística por un 0,83%.

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta:
estudio comparativo

Comparación de Análisis Discriminante, Regresión Logística, Redes Neuronales y Ensamblados.




Figura 8.46 Gráfico de caja y bigotes para los resultados de todos los algoritmos considerados para el caso M2 35Hz F_{123} .

Comparación de Análisis Discriminante, Regresión Logística, Redes Neuronales y Ensamblados.




Figura 8.47 Gráfico de caja y bigotes para los resultados de todos los algoritmos considerados para el caso M2 35Hz F_3 .

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

Tabla 8.23 Resumen de las diferencias en el desempeño entre los algoritmos considerados para la clasificación F_{123} y el grupo de ensayos M2 35 Hz. Se calcula, para cada clasificación, la diferencia entre desempeño del algoritmo A y el B y se muestra el promedio, la cantidad de veces que tuvieron el mismo porcentaje de clasificación correcta, cuantas veces el algoritmo A fue mejor y cuantas lo fue el algoritmo B.

Algoritmo A	Algoritmo B	Promedio de la diferencia de A- B	Igual desempeño	A fue mejor	B fue mejor
Regresión L.	Análisis D.	1,34%	0	60	40
Redes N.	Análisis D.	10,46%	0	954	46
Redes N.	Regresión L.	9,12%	2	928	70
Ensamble 3	Redes N.	1,41%	144	558	298
Ensamble 10	Redes N.	1,90%	167	609	224
Ensamble 3	Análisis D.	11,87%	0	99	1
Ensamble 10	Análisis D.	12,36%	0	100	0
Ensamble 3	Regresión L.	10,53%	0	97	3
Ensamble 10	Regresión L.	11,02%	0	97	3
Ensamble 10	Ensamble 3	0,48%	31	40	29

Tabla 8.24 Resumen de las diferencias en el desempeño entre los algoritmos considerados para la clasificación F_3 y el grupo de ensayos M2 35Hz. Se calcula, para cada clasificación, la diferencia entre desempeño del algoritmo A y el B y se muestra el promedio, la cantidad de veces que tuvieron el mismo porcentaje de clasificación correcta, cuantas veces el algoritmo A fue mejor y cuantas lo fue el algoritmo B.

Algoritmo A	Algoritmo B	Promedio de la diferencia de A- B	Igual desempeño	A fue mejor	B fue mejor
Regresión L.	Análisis D.	-0,83%	0	39	61
Redes N.	Análisis D.	9,78%	1	940	59
Redes N.	Regresión L.	10,61%	28	886	86
Ensamble 3	Redes N.	0,72%	452	338	210
Ensamble 10	Redes N.	1,49%	483	380	137
Ensamble 3	Análisis D.	10,49%	0	96	4
Ensamble 10	Análisis D.	11,27%	0	100	0
Ensamble 3	Regresión L.	11,33%	2	93	5
Ensamble 10	Regresión L.	12,11%	1	94	5
Ensamble 10	Ensamble 3	0,78%	60	26	14

8.6.5 Promedio de todos los casos considerados

En las secciones anteriores se compararon los 5 algoritmos considerados en este trabajo para algunos grupos de ensayos. En esta sección se presenta el promedio de los resultados considerando los 20 grupos de ensayos.

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta:
estudio comparativo

La Tabla 8.25 presenta el promedio de todos los casos considerados para los dos motores. La cantidad de veces que los algoritmos tuvieron el mismo desempeño y la cantidad de veces que uno fue mejor que el otro, se presentan en forma de porcentaje.

Tabla 8.25 Resumen de las diferencias en el desempeño entre los algoritmos considerados para la clasificación F_{123} y promediando todos los casos. Se calcula, para cada clasificación, la diferencia entre desempeño del algoritmo A y el B y se muestra el promedio, el porcentaje de veces que tuvieron el mismo desempeño, el porcentaje de veces que el algoritmo A fue mejor y el porcentaje de veces que el algoritmo B fue superior.

Algoritmo A	Algoritmo B	Promedio de la diferencia de A- B	Igual desempeño	A fue mejor	B fue mejor
Regresión L.	Análisis D.	2,84%	31,15%	52,40%	16,45%
Redes N.	Análisis D.	5,13%	30,29%	56,79%	12,93%
Redes N.	Regresión L.	2,29%	36,86%	43,62%	19,53%
Ensamble 3	Redes N.	1,04%	47,66%	36,64%	15,70%
Ensamble 10	Redes N.	1,34%	48,69%	39,51%	11,81%
Ensamble 3	Análisis D.	6,17%	32,60%	60,30%	7,10%
Ensamble 10	Análisis D.	6,47%	32,65%	61,75%	5,60%
Ensamble 3	Regresión L.	3,33%	40,70%	48,60%	10,70%
Ensamble 10	Regresión L.	3,63%	42,15%	49,60%	8,25%
Ensamble 10	Ensamble 3	0,30%	64,35%	22,50%	13,15%

Tabla 8.26 Resumen de las diferencias en el desempeño entre los algoritmos considerados para la clasificación F_{123} y promediando todos los casos del Motor 1. Se calcula, para cada clasificación, la diferencia entre desempeño del algoritmo A y el B y se muestra el promedio, el porcentaje de veces que tuvieron el mismo desempeño, el porcentaje de veces que el algoritmo A fue mejor y el porcentaje de veces que el algoritmo B fue superior.

Algoritmo A	Algoritmo B	Promedio de la diferencia de A- B	Igual desempeño	A fue mejor	B fue mejor
Regresión L.	Análisis D.	0,00%	70,14%	18,57%	11,29%
Redes N.	Análisis D.	0,07%	71,01%	20,39%	8,60%
Redes N.	Regresión L.	0,07%	77,81%	15,01%	7,17%
Ensamble 3	Redes N.	0,38%	88,03%	10,37%	1,60%
Ensamble 10	Redes N.	0,39%	88,66%	10,56%	0,79%
Ensamble 3	Análisis D.	0,45%	74,29%	23,14%	2,57%
Ensamble 10	Análisis D.	0,46%	74,14%	23,57%	2,29%
Ensamble 3	Regresión L.	0,45%	80,86%	18,29%	0,86%
Ensamble 10	Regresión L.	0,47%	81,86%	18,14%	0,00%
Ensamble 10	Ensamble 3	0,01%	97,14%	2,00%	0,86%

Analizando la Tabla 8.25 se concluye que el Análisis Discriminante fue el que obtuvo los peores resultados para el promedio de los casos, pues en la comparación con los otros 4 algoritmos se evidencia una inferioridad del mismo.

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

Comparando las Redes Neuronales con los Ensamblados, se observa que el Ensamble de 3 ANN fue un 1,04% superior y el Ensamble de 10 ANN lo fue en un 1,34%.

La Regresión Logística obtuvo mejores resultados únicamente al compararse con el Análisis Discriminante, pues al compararse con las Redes Neuronales obtuvo un porcentaje de clasificación correcta un 2,29 % inferior. También el Ensamble de 10 ANN y el Ensamble de 3 ANN fueron un 3,33 % y 3,63 % superiores a la Regresión Logística.

En los dos tipos de ensamblados, el Ensamble de 10 ANN presentó unos resultados solamente un 0,3% superiores a los del Ensamble de 3 ANN. Además, esta es la única comparación de la tabla donde más de la mitad de las veces los algoritmos obtuvieron el mismo porcentaje de clasificación.

La Tabla 8.26 presenta el resumen de resultados para los casos que utilizan ensayos del Motor 1 únicamente.

La Tabla 8.26 muestra el promedio de los resultados de los ensayos hechos al Motor 1. Se puede apreciar que, debido a que todos los algoritmos clasificaron correctamente la gran mayoría de los ensayos, las diferencias entre los resultados de los métodos son muy bajas. Así, se observa en la columna que indica en cuantas ocasiones ambos algoritmos obtuvieron el mismo porcentaje de clasificación correcta, que los métodos tuvieron el mismo desempeño de la mayoría de las ocasiones. De hecho, el Ensamble de 10 ANN y el Ensamble de 3 ANN tuvieron el mismo desempeño en el 97,14 % de las veces.

En cuanto a eficiencia, el Análisis Discriminante y la Regresión Logística obtuvieron resultados prácticamente idénticos. Las Redes Neuronales fueron un poco superiores a los dos métodos estadísticos y los ensamblados ligeramente mejores que las redes simples. Sin embargo, la diferencia en los ensamblados es muy pequeña, de sólo el 0,01%.

También se presentan, en la Tabla 8.27 los mismos resultados para los ensayos obtenidos con el Motor 2.

Estos resultados son muy parecidos a los obtenidos con todos los ensayos de ambos motores (Tabla 8.25) pero con los ensayos del Motor 2 las diferencias entre los algoritmos son más notorias. Esto se debe a que, al promediar los resultados con los

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

ensayos realizados al Motor 1, estas diferencias disminuyen debido a que los resultados obtenidos con ensayos del Motor 1 son muy similares con todos los algoritmos, como se evidencia en la Tabla 8.26.

Tabla 8.27 Resumen de las diferencias en el desempeño entre los algoritmos considerados para la clasificación F_{123} y promediando todos los casos del Motor 2. Se calcula, para cada clasificación, la diferencia entre desempeño del algoritmo A y el B y se muestra el promedio, el porcentaje de veces que tuvieron el mismo desempeño, el porcentaje de veces que el algoritmo A fue mejor y el porcentaje de veces que el algoritmo B fue superior.

Algoritmo A	Algoritmo B	Promedio de la diferencia de A- B	Igual desempeño	A fue mejor	B fue mejor
Regresión L.	Análisis D.	4,36%	10,15%	70,62%	19,23%
Redes N.	Análisis D.	7,86%	8,35%	76,38%	15,26%
Redes N.	Regresión L.	3,49%	14,80%	59,02%	26,18%
Ensamble 3	Redes N.	1,39%	25,92%	50,78%	23,29%
Ensamble 10	Redes N.	1,84%	27,16%	55,09%	17,75%
Ensamble 3	Análisis D.	9,24%	10,15%	80,31%	9,54%
Ensamble 10	Análisis D.	9,70%	10,31%	82,31%	7,38%
Ensamble 3	Regresión L.	4,88%	19,08%	64,92%	16,00%
Ensamble 10	Regresión L.	5,34%	20,77%	66,54%	12,69%
Ensamble 10	Ensamble 3	0,46%	46,69%	33,54%	19,77%

En los resultados obtenidos con ensayos del Motor 2 también se aprecia que el Análisis Discriminante fue al algoritmo con peor desempeño. La Regresión Logística fue mejor que el Análisis Discriminante pero inferior que los métodos basados en redes neuronales.

Con estos resultados la diferencia entre las Redes Neuronales y los ensambles es más notoria, además de ser mayor la diferencia en desempeño también se aprecia que el Ensamble de 10 ANN clasificó mejor a los ensayos en un 55,09% de las ocasiones y el Ensamble de 3 ANN fue mejor que las Redes Neuronales en el 50,78% de las veces.

En este caso el Ensamble de 10 ANN también fue mejor que el Ensamble de 3 ANN, aunque la diferencia fue nuevamente pequeña, menos del 0,5% y en casi la mitad de las ocasiones tuvieron el mismo desempeño.

8.6.6 Conclusión de la comparación de algoritmos:

En esta sección se presentó una comparación del desempeño de los algoritmos estudiados en esta tesis, Análisis Discriminante, Regresión Logística, Redes Neuronales, Ensamble de 10 ANN y Ensamble de 3 ANN.

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

Analizando primeramente los resultados obtenidos con ensayos del Motor 1 concluimos que todos los algoritmos obtuvieron rendimientos muy elevados. Por ejemplo, con los ensayos realizados el Motor 1 con alimentación de variador Altivar a 65 Hz todos los métodos clasificaron correctamente el 100% de los ensayos al emplear el conjunto reducido de características. Esto es congruente con el análisis de variables realizado en el capítulo 7 donde se mostró que la característica Momento 1 (ver Fig. 7.13) puede discriminar perfectamente entre los cuatro estados de fallo considerados. Comparando los resultados obtenidos por el Análisis Discriminante con los conseguidos por la Regresión Logística observamos que, en promedio, ambos tuvieron el mismo rendimiento. Estos resultados son consecuentes con el hecho de que las características presentaban relaciones lineales con el deslizamiento y poder discriminante significativo para la mayoría de los grupos de ensayos del Motor 1. Sin embargo, al asociar ensayos realizados con distintas alimentaciones, la clasificación se dificulta un poco y algunos ensayos no pueden ser clasificados correctamente por los métodos estadísticos. En estos casos se observa un rendimiento ligeramente superior de los métodos basados en Redes Neuronales. Aunque, al ser los rendimientos superiores al 99% en casi todos los casos las diferencias no pueden ser consideradas significativas.

Recordando el análisis de variables realizado en el capítulo 7 se observó como las características de los ensayos realizados al Motor 2 tenían relaciones más complejas tanto con el deslizamiento como con los estados de fallo. Por ejemplo, el Factor de Forma de los ensayos obtenidos con variador Allen Bradley a 35 Hz (Fig. 7.23) presentaba relaciones no lineales con los estados de fallo y con el nivel de carga del motor representado por el deslizamiento. Considerando esto, se espera que el rendimiento del Análisis Discriminante sea inferior a los otros algoritmos al considerar solamente divisiones lineales entre las clases o estados de fallo. Esta hipótesis es congruente con los resultados observados en la Tabla 8.27 donde el Análisis Discriminante es superado por los otros algoritmos en cuanto a rendimiento. Al introducir las Redes Neuronales, que según se ha mencionado son aproximadores universales, se espera que una red con suficientes neuronas en la capa oculta pueda aproximar cualquier función continua. Esta característica debería dar ventaja a las Redes Neuronales sobre la Regresión Logística al clasificar ensayos con relaciones no lineales y complejas debido a que la Regresión Logística, si bien puede aproximar funciones no lineales, al hacerlo subestima estas relaciones en ciertas regiones del espacio. Al

Capítulo 8: Resultados de la aplicación de la metodología de diagnóstico propuesta: estudio comparativo

comparar los resultados obtenidos por la Regresión Logística con los conseguidos por las Redes Neuronales se aprecia que, como se suponía, al trabajar con un grupo de ensayos más difíciles de clasificar como los realizados al Motor 2, las Redes Neuronales obtuvieron mayores porcentajes de clasificación correcta que la Regresión Logística.

Al introducir el Ensamble de Redes Neuronales en el capítulo 4 se mencionó que, en teoría, este conjunto de clasificadores debería conseguir mejores resultados en promedio que las Redes Neuronales simples y con una varianza menor, es decir, los porcentajes de clasificación correcta deberían ser más altos y depender menos de la división de los ensayos utilizados para entrenar y validar al método. Los resultados conseguidos son totalmente congruentes con esta teoría. En todos los casos, los ensambles obtuvieron rendimientos más elevados con menos varianza que las Redes Neuronales. Al comparar el Ensamble de 10 ANN con el Ensamble de 3 ANN observamos que para el Motor 1 ambos obtuvieron resultados prácticamente iguales, aunque esto podría deberse a la facilidad de clasificación que presentaron los ensayos del Motor 1. Al considerar los ensayos del Motor 2, el Ensamble de 10 ANN obtuvo un resultado un 0,46% mejor que el Ensamble de 3 ANN, aunque se debe recordar que el esfuerzo computacional necesario para implementar el Ensamble de 10 ANN es mayor. Por lo tanto, correspondería al encargado de mantenimiento, de acuerdo a los recursos que disponga y a la necesidad de obtener un nivel de clasificación más alto, determinar si emplea el método más eficaz pero más demandante de recursos computacionales, Ensamble de 10 ANN, o el Ensamble de 3 ANN, que ofrece resultados ligeramente inferiores pero con un consumo de recursos mayores. Cabe resaltar que, a diferencia del proceso de reducción del número de variables, donde se reduce el esfuerzo computacional sin afectar significativamente el rendimiento de los algoritmos, en este caso hay un mayor esfuerzo computacional para conseguir rendimientos mayores. Debería ser estudiado en cada caso si un incremento del 0,46% en el rendimiento del Ensamble de 10 ANN compensa la mayor necesidad de recursos computacionales.

Finalmente, se puede concluir que al aumentar la complejidad de las relaciones de las variables entre sí y con los estados de fallo, es decir, al aumentar la dificultad de clasificación del conjunto de ensayos, los Ensamblados de Redes Neuronales obtienen rendimientos más altos que los otros métodos y con varianzas menores, es decir, porcentajes de clasificación mayores y menos dependientes de la división de los ensayos en grupos de entrenamiento y validación.

9 Conclusiones y trabajos futuros

En la primera sección de este capítulo se exponen las principales aportaciones y conclusiones del presente trabajo. La segunda sección describe los posibles trabajos que se proponen para continuar con la línea de investigación seguida por la presente tesis.

9.1 Aportaciones y conclusiones

Esta tesis propone una metodología para el diagnóstico de fallos en máquinas eléctricas con un enfoque eminentemente práctico, orientado hacia el mantenimiento predictivo basado en la monitorización del estado, en este caso, del motor de inducción. En este trabajo, la metodología propuesta se implementó con dos objetivos claros: la detección del fallo de barras rotas en motores de inducción, y el diagnóstico de la severidad de esta avería. El procedimiento propuesto es genérico, de forma que sería aplicable a otros tipos de fallos. A continuación se describen las principales aportaciones hechas en la tesis:

- La presente tesis propone una metodología basada en ensamble de Redes Neuronales para el diagnóstico de fallos en máquinas eléctricas cuyas principales características son:
 - La primera etapa de la metodología consiste en un proceso de dos etapas, análisis de correlación simple y Análisis Discriminante, que permite reducir el número de variables indicativas de fallo para disminuir el esfuerzo computacional y emplear sólo las características necesarias para el diagnóstico.
 - La metodología permite combinar variables indicativas de fallo de diferentes orígenes. De hecho, en el presente trabajo se emplearon por primera vez en el mismo algoritmo de clasificación los siguientes conjuntos de variables:
 - Variables estadísticas calculadas en el dominio del tiempo de la señal.
 - Características calculadas en el dominio de la frecuencia con la Transformada de Fourier.
 - Características del módulo de la señal analítica calculado con la Transformada de Hilbert.

Capítulo 9: Conclusiones y trabajos futuros

- La metodología permite diagnosticar el motor de acuerdo a la importancia del mismo, proponiendo estrategias de clasificación diferentes para máquinas con diferentes niveles de importancia o criticidad (dentro del proceso productivo o aplicación industrial). Así, se proponen cuatro estrategias de clasificación diferentes:
 - Para un caso general: se propone optimizar el algoritmo para clasificar los ensayos en cuatro grupos o estados de fallos: i) Motor Sano, ii) Fallo Leve, iii) Fallo Medio y iv) Barra Rota.
 - Para un motor de muy alta importancia: se clasifican los ensayos en dos grupos: i) Motor Sano, ii) Motor con Fallo (incluye los estados: Fallo Leve, Fallo Medio y Barra Rota). Es decir, sólo clasifica a un motor entre sano o no sano, pues, por su importancia, se considera que incluso un fallo incipiente debe ser atendido.
 - Para un motor importante: se discriminan los ensayos en dos grupos: i) Motor Sano o con avería menor (incluye los estados de fallo Motor Sano y Fallo Leve) y ii) Fallo Medio o mayor (incluye los estados de fallo: Fallo Medio y Barra Rota). En este caso se considera que una avería incipiente todavía no es preocupante y recién cuando el fallo progresa hasta ser un Fallo Medio se deben tomar medidas.
 - Para un motor de baja importancia: sólo se discrimina entre motor con Barra Rota o no, es decir, se separan los ensayos en dos grupos: i) Motor sin barra completamente rota (constituido por los estados de fallo: Motor Sano, Fallo Leve y Fallo Medio) y ii) Motor con Barra Rota. Cuando la importancia del motor en el proceso industrial es menor se puede considerar que solamente es necesario tomar acciones de mantenimiento cuando la avería ha alcanzado una extensión mayor y no antes. Por tanto, esta estrategia de clasificación informa solamente cuando hay una Barra Rota y no discrimina entre un motor sano o con una avería incipiente.
- Estas formas de clasificación permitirían al encargado de mantenimiento disponer de información útil en función de la importancia del motor y

Capítulo 9: Conclusiones y trabajos futuros

poder organizar de forma más efectiva sus recursos, con el objetivo de realizar un mantenimiento más eficiente y económico.

- La metodología ha demostrado ser robusta al obtener resultados de gran calidad empleando ensayos obtenidos con diferentes fuentes de alimentación y dos motores de distintas características, por lo que puede ser empleada tanto para diagnosticar máquinas alimentadas de red como con variador de frecuencia. Cabe resaltar que el comportamiento complejo de algunas de las características y la gran cantidad de fuentes de alimentación distintas consideradas representan un reto para la metodología de diagnóstico.
- Tal como se explicó en la sección 6.3.2, teóricamente las características espectrales necesitan que la señal medida se haya capturado con la máquina funcionando en estado estacionario puro para evitar errores en el cálculo de las variables. Sin embargo, en la industria no siempre es sencillo obtener mediciones sin ninguna variación, por lo que en esta tesis se decidió aceptar también mediciones con ligeras variaciones de carga. El alto porcentaje de clasificación correcta obtenido por el método propuesto demuestra la robustez del mismo ante este tipo de ensayos no ideales o con ligeras variaciones de carga durante el muestreo de la señal.
- Para medir el rendimiento de una técnica de diagnóstico, generalmente se dividen los ensayos disponibles en un grupo de entrenamiento, con el que se entrena o ajustan los parámetros de la técnica de diagnóstico, y otro grupo de validación con el que se prueba la técnica y se da una estimación del rendimiento del método. El inconveniente de esta forma de evaluar el rendimiento es que depende de la división que se haga de los ensayos y puede variar mucho dependiendo de qué ensayos se empleen para entrenar el método y cuáles para validarlo. Para medir apropiadamente el rendimiento de la metodología propuesta, se implementó un esquema de validación cruzada de 10 iteraciones. Este esquema, descrito en la sección 6.4 b, permite obtener una evaluación más fiable de la metodología propuesta.
- Se empleó un porcentaje de clasificación correcta ponderada como medida del rendimiento de la metodología (ver sección 6.4.c). Al clasificar un grupo de ensayos en distintas clases o estados de fallo, no

todas las clases tienen la misma cantidad de ensayos, por lo que para los algoritmos es más difícil clasificar correctamente los ensayos pertenecientes a las clases con menos elementos. Así, el porcentaje de clasificación correcta ponderado da mayor importancia a clasificar correctamente ensayos pertenecientes a clases con menos elementos, por lo que es una estimación más realista del rendimiento de la metodología propuesta.

- La metodología es capaz de diagnosticar fallos incipientes, lo cual es esencial para motores de muy alta importancia. También puede discriminar entre averías medias de barras totalmente rotas. Esto permite que la metodología pueda ser empleada tanto para realizar el seguimiento periódico de la progresión de una avería como para el diagnóstico ocasional de una máquina.
- Cabe destacar que los ensayos con que fue probada la metodología cubren rangos de operación del motor desde vacío hasta plena carga, con lo que se demostró que la metodología propuesta es capaz de diagnosticar correctamente incluso ensayos realizados a baja carga. Además, se realizaron ensayos con diferentes tipos de alimentación, como son alimentación de red y con dos variadores diferentes a tres frecuencias distintas, 35 Hz, 50 Hz y 65Hz. Cabe resaltar que el asociar ensayos obtenidos a distintas frecuencias representa una mayor dificultad para el algoritmo encargado de diagnosticar y que aún en este caso la metodología propuesta alcanzó un alto rendimiento.
- Se estudió y comprobó la utilidad de las características estadísticas aplicadas a la señal de la corriente estática. Si bien este tipo de características son ampliamente utilizadas con señales de vibraciones, aún son relativamente escasos los estudios que las emplean con señales de corriente.
- Si bien el estado estable de la corriente es necesario para el cálculo de las características espectrales utilizadas en esta tesis, la independencia del proceso de selección de variables y entrenamiento del algoritmo de Redes Neuronales, permitirá la implementación de la metodología con señales transitorias, una vez seleccionadas las características que puedan

ser calculadas con señales no estacionarias, como pueden ser índices basados en Wavelets, o la transformada de Wigner-Ville entre otros.

- Se empleó una forma sencilla y eficiente de seleccionar sólo un número reducido de las Redes Neuronales para formar parte del Ensamble de Redes Neuronales. La forma de selección consiste en ordenar a las Redes Neuronales de acuerdo a su eficiencia para clasificar al grupo de Prueba y luego elegir el subconjunto de las “n” mejores Redes Neuronales para formar parte del ensamble.
- Para validar los resultados de la metodología propuesta se compararon con dos técnicas estadísticas de clasificación, el Análisis Discriminante y la Regresión Logística. Como se vio en el capítulo 8, el rendimiento de la metodología propuesta fue superior al alcanzado por las dos técnicas estadísticas en todos los casos. Además, se observó que mientras más complicado de clasificar es el grupo de ensayos, por ejemplo, cuando se asocian ensayos obtenidos a frecuencias distintas y con alimentadores distintos, más grande es la diferencia de rendimiento a favor de la metodología propuesta. Esto se debe a que al asociar ensayos obtenidos con distintos tipos de alimentación se requiere que el algoritmo de clasificación aprenda las relaciones complejas y no-lineales entre las variables indicativas de fallo. Como se vio en el capítulo 4, las Redes Neuronales, con suficientes neuronas en la capa oculta, son capaces de aprender relaciones no-lineales y complejas, mientras que el Análisis Discriminante sólo realiza separaciones lineales y la Regresión Logística, si bien puede realizar separaciones con cierta no-linealidad, al aumentar la complejidad va subestimando las curvaturas de las funciones y comete más errores de clasificación.
- En trabajos previos se ha propuesto que, mediante el módulo de la señal analítica, se puede evaluar la amplitud de la banda lateral superior al armónico principal, relacionada con el fallo por barra rota, de forma eficiente aún a deslizamientos bajos.
 - En esta tesis se ha extendido esta metodología para calcular también la amplitud de bandas laterales alrededor de armónicos superiores.
 - Se mostró, mediante un análisis estadístico de análisis discriminante, que estas características propuestas contienen información útil y complementan la información contenida en las características calculadas

de forma tradicional. Cabe resaltar que no se pretende que estas nuevas características suplanten a las tradicionales obtenidas del Power Spectral Density, sino que complementen a las mismas para lograr un mejor diagnóstico.

- Para el desarrollo de esta tesis se realizaron 1679 ensayos con dos motores y tres variadores diferentes, con deslizamientos bajos, medios y altos. Estos ensayos constituyen una nueva base de datos para poder evaluar y comparar nuevas técnicas de diagnóstico.

En resumen, a lo largo de la presente tesis se demostró que la metodología propuesta cumple con el objetivo general trazado, es decir, es una metodología que al combinar técnicas estadísticas y Ensamble de Redes Neuronales logra un alto rendimiento de clasificación correcta ponderada, aun considerando ensayos no ideales, con gran variación del nivel de carga del motor y ensayos obtenidos con alimentaciones diferentes de red y variador a distintas frecuencias. Además, esta metodología, al estar orientada al mantenimiento, permite asignar distintos niveles de importancia al motor a la hora de realizar el diagnóstico. Todas estas características hacen de esta metodología una herramienta útil para el mantenimiento predictivo de fallos en motores de inducción.

9.2 Trabajos futuros

Los posibles trabajos futuros que se proponen para continuar con la línea de investigación seguida en la presente tesis son:

- Una de las principales limitaciones de la metodología propuesta en esta tesis, y de los modelos de diagnóstico basados en datos en general (sección 3.4), es que es necesaria una gran cantidad de ensayos para entrenar convenientemente los algoritmos, a fin de poder utilizarlos como técnicas de diagnóstico. A nivel industrial, puede no resultar práctico obtener esta cantidad de ensayos para diferentes tipos de motores. Para subsanar este inconveniente, se propone estudiar la eficacia de entrenar los algoritmos de clasificación con señales obtenidas mediante simulaciones con elementos finitos de los motores y comprobar su desempeño diagnosticando señales de motores reales.

Capítulo 9: Conclusiones y trabajos futuros

- Comprobar la eficiencia de la metodología para diagnosticar otros tipos de fallos: cortocircuito en el estator, fallos en los rodamientos, desequilibrio del eje, entre otros. Se deberá poner especial atención en el análisis de las características estadísticas, pues podrían tener comportamientos similares con fallos de naturaleza distinta.
- Estudiar las razones físicas del comportamiento de las características estadísticas pues, como se vio en el capítulo 7 de este trabajo, algunas de ellas presentan una relación compleja con el estado de fallo del motor.
- En esta tesis se emplearon Ensamblajes de Redes Neuronales de estructuras iguales y entrenadas con el mismo conjunto de datos. Se puede mejorar la eficiencia de las mismas utilizando redes con estructuras diferentes, utilizando grupos diferentes de ensayos para su entrenamiento, o combinando a las redes neuronales con otros algoritmos de clasificación.
- Emplear otras técnicas de clasificación basadas en inteligencia artificial en sustitución de las redes neuronales, como pueden ser las máquinas de vectores de soporte.
- Combinar características obtenidas del estado estable de la corriente con índices calculados con el estado transitorio a fin de lograr una mayor eficiencia en el diagnóstico.
- Las técnicas consideradas para la selección de variables, análisis de regresión simple y Análisis Discriminante, solamente consideran relaciones lineales entre las variables. Se pueden implementar otras técnicas para la reducción de la dimensionalidad de los datos que consideren también relaciones no lineales entre las características, como por ejemplo el Análisis de Componentes Principales Curvilíneo.

Referencias

- [ACO06] Acosta G.G., Verucchi C.J. y Gelso E.R., "A current monitoring system for diagnosing electrical failures in induction motors", *Mechanical Systems and Signal Processing*, vol.:4, pp.: 953-965, 2006.
- [AHA12] Ahameda S. K., Sarkarb A., Mitrac M. y Senguptad S., "Detection of induction motor broken bar fault through envelope analysis using start-up current", *Procedia Technology* vol.: 4, pp.: 646–651, 2012.
- [AHM05] Ahmed I., Ertugrul N., y Soong W. L., "A Study on the Detection of Fault Frequencies for Condition Monitoring of Induction Machines," en *proceedings de: Australian Universities Power Engineering Conference, Tasmania, Australia 2005*.
- [AHM07] Ahmed, I. "Investigation of Single and Multiple Faults Under Varying Load Conditions Using Multiple Sensor Types to Improve Condition Monitoring of Induction Machines" tesis doctoral, Universidad de Adelaide, Australia, 2007.
- [AKI08a] Akin B., Orguner U., Toliyat H. A., y Rayner M., "Low order PWM inverter harmonics contributions to the inverter-fed induction machine fault diagnosis," *IEEE Transaction Industrial Electronics*, vol. 55, no. 2, pp. 610–619, feb. 2008.
- [AKI08b] Akin B., Orguner U., Toliyat H. A., y Rayner M., "Phase-sensitive detection of motor fault signatures in the presence of noise," *IEEE Transaction Industrial Electronics*, vol. 55, no. 6, pp. 2539–2550, jun. 2008.
- [ALB83] Albrecht, P.F., et al. "Assessment of the Reliability of Motors in Utility Applications". *IEEE/PES Summer Meeting, Los Angeles, 1983*.
- [ALB86] Albrecht, P.F., J.C: Appiarius y R.M. McCoy "Assessment of the Reliability of Motors in Utility Applications". *IEEE Transactions on Energy Conversion* vol.1, n°1 pp. 39-46, 1986
- [ALL01] "Variable frequency drives optimize performance and protection of offshore oil electric submersible pumps," en *Allen "Bradley Variable Frequency Drives Application Notes, 2001. Milwaukee, WI: Rockwell Automation. Disponible online: http://www.ab.com/drives/energy_savings/Application%20Profiles-Whitepapers/ElecSubPump.pdf*
- [ALM99] Almeida, L. B., Langlois, T., Amaral, J. D. y Plakhoy, A.: "Parameter adaptation in stochastic optimization". En: D. Saad (Ed.), *On-line Learning in Neural Networks*, capítulo 6, pp. 111- 134. Cambridge University Press, 1999.
- [AMR08] Amrei, S.R.H. y Xu, D.G., "A new study on harmonics and interharmonics reduction with frequency selective closed-loop control in VSI inverters," *IEEE Conference on Vehicle Power and Propulsion, VPPC '08.*, pp.1-6, set. 2008.
- [AND88] Anderson J.A. y Rosenfeld E., "Neurocomputing: Foundations of Research", MIT Press, Cambridge, Mass., 1988.
- [ANT06] Antonino-Daviu J., Riera-Guasp M., Roger-Folch J. y Palomares M., "Validation of a new method for the diagnosis of rotor bar failures via wavelet transform in industrial induction machines", *IEEE Transactions on Industry Applications* vol.42, n° 4, 2006.
- [ANT07] Antonino-Daviu J., Jover P., Riera M., Arkkio A., Roger-Folch J., "DWT analysis of numerical and experimental data for the diagnosis of dynamic eccentricities in induction motors", *Mechanical Systems and Signal Processing* vol.21, n°6, pp. 2575-2589, 2007.
- [ANT09a] Antonino-Daviu J., Rodriguez P.J., Riera-Guasp M., Pineda-Sanchez M. y Arkkio A., "Detection of combined faults in induction machines with stator parallel

Referencias

- branches through the DWT of the startup current”, *Mechanical Systems and Signal Processing* vol.: 23, n°: 7, pp.:2336-2351, 2009.
- [ANT09b] Antonino-Daviu J., Climente-Alarcón V., Pons-Llinares J., Pineda-Sánchez M., Jover-Rodríguez P. y Arkkio A. “Application of TFD tools for the tracing of eccentricity-related components in induction machines”, en proceedings de: IEEE 35th Annual Conference of Industrial Electronics, IECON09, 2009.
- [ARO07] Aroui T., Koubaa Y. y Toumi A. "Application of Feedforward Neural Network for Induction Machine Rotor Faults Diagnostics using Stator Current" *JES Journal of Electrical Systems*, disponible on-line : <http://journal.esrgroups.org/jes/>, ISSN 1112-5209, 2007
- [ARU95] Arui Q.Q., “Diagnosis of rotor fault in squirrel cage induction motors using time-varying frequency spectrum of starting stator current”, en proceedings de: Chinese Society Electrical Engineering, pp. 267-273, 1995.
- [AWA03] Awadallah M.A. y Morcos M.M., “Application of AI tools in fault diagnosis of electrical machines and drives an overview”, *IEEE Transactions on Energy Conversion* vol.18, n° 2, pp.: 245-251, 2003.
- [AYD11] Aydin I., Karakose M. y Akin E., “A new method for early fault detection and diagnosis of broken rotor bars”, *Energy Conversion and Management* vol.52, n° 4, pp.: 1790-1799, 2011.
- [AYH06] Ayhan B., Chow M.Y. y Song M.H., “Multiple discriminant analysis and neural-network-based monolith and partition fault-detection schemes for broken rotor bar in induction motors”, *IEEE Transactions on Industry Electronics* vol.53, n° 4, pp.: 1298-1308, 2006.
- [AYH08] Ayhan B., Trussell J., Chow M.Y. y Song M.H., “On the use of a lower sampling rate for broken rotor bar detection with DTFT and AR-based spectrum methods”, *IEEE Transactions on Industrial Electronics* vol.55, n° 3, pp.: 1421-1434, 2008.
- [BAB06] Babaa F., Oumaamar M.E.K., Khezzer A. y Boucherma M., “Multiple coupled circuit modeling of squirrel cage induction motors including space harmonics and line neutral voltage”, en proceedings of the International Conference on Electrical Machines, Chania, Greece, 2006.
- [BAC07] Bacha K., Henaob H., Gossa M. y Capolino G.A., “Induction machine fault detection using stray flux EMF measurement and neural network-based decision”, *Electric Power Systems Research* n°78, vol.7 , pp.: 1247-1255, 2007.
- [BAN99] Bangura J. F. y Demerdash N. A., “Diagnosis and Characterization of effects of Broken Rotor Bars and Connectors in Squirrel-Cage Induction Motors by a Time-Stepping Coupled Finite Element-State Space Modeling Approach,” *IEEE Transactions on energy Conversion*, vol. 15, pp. 1167-1176, dic. 1999.
- [BEG99] Beguenane R. y Benbouzid M.E.H., “Induction Motors Thermal Monitoring By Means of Rotor-Resistance Identification”, *IEEE Transaction on Energy Conversion*, vol. 3, n° 14, pp 566–570 , set. 1999.
- [BEL00] Bellini, A., Filippetti, F., Franceschini, G. y Tassoni, C., "Closed-loop control impact on the diagnosis of induction motors faults," *IEEE Transactions on Industry Applications*, vol. 5, no.36, pp.1318-1329, set./oct. 2000.
- [BEL01] Bellini A., Filippetti F., Franceschini G., Tassoni C. y Kliman G. B., “Quantitative evaluation of induction motor broken bars by means of electrical signature analysis”, *IEEE Transactions on Industry Applications* vol.37, n° 5, pp.: 1248-1255, 2001.
- [BEL02] Bellini A., Filippetti F., Franceschini G., Tassoni C., Passaglia R., Saottini M., Tontini G., Giovannini M. y Rossi A., “On-field experience with online diagnosis

Referencias

- of large induction motors cage failures using MCSA”, IEEE Transactions on Industry Applications vol.38, n° 4, pp.: 1045-1053, 2002.
- [BEL08a] Bellini A., Filippetti F., Tassoni C. y Capolino G.A., “Advances in diagnostic techniques for induction machines”, IEEE Transactions on Industrial Electronics, vol.55 n° 12, pp.: 4109-4126, 2008.
- [BEL08b] Bellini A., Yazidi A., Filippetti F., Rossi C. y Capolino G.A., “High frequency resolution techniques for rotor fault detection of induction machines”, IEEE Transactions on Industry Electronics vol.55, n° 12, pp.: 4200-4209, 2008.
- [BEN99] Benbouzid M., Beguenane R., y Vieira M., "Induction Motor Asymmetrical Faults Detection Using Advanced Signal Processing Techniques”, IEEE Transaction on Energy Conversion, vol. 14, n° 2, pp.: 147-152, jun. 1999.
- [BEN03] Benbouzid M.E.H. y Kliman G.B., “What stator current processing-based technique to use for induction motor rotor faults diagnosis”, IEEE Transactions on Energy Conversion vol.18, n° 2, pp.: 238-244, 2003.
- [BET03] Bethel N.P., “The new role of current analysis in predictive maintenance”, AISE steel technology vol.80, n° 1, pp.: 45-5, 2003.
- [BIK06] Bikfalvi P. y Imecs M., “Rotor fault detection in induction machines: Methods and techniques State-of-the-Art”, en proceedings de: IEEE International Conference on Automation, Quality and Testing, Robotics, pp.: 199-204, 2006.
- [BIS95] Bishop C. M. “Neural Networks for Pattern Recognition”, Clarendon Press, Oxford 1995.
- [BLA97] Blasco-Gimenez R., Hurst K.D. y Habetler T.G., “Comments on sensorless speed measurement using current harmonic spectral estimation in induction machine drives”, IEEE Transactions on Power Electronics vol.12, n° 5, pp.: 938-940, 1997.
- [BON88] Bonnett, A.H. y Soukup, G.C., “Analysis of rotor failures in squirrel-cage induction motors”, IEEE Transactions on Industry Applications, vol.24, n° 6, pp.: 1124-1130, nov./dic. 1988.
- [BON92a] Bonnett, A.H. y Soukup, G.C., “Cause and analysis of stator and rotor failures in three-phase squirrel-cage induction motors”, IEEE Transactions on Industry Applications, vol.28, n° 4, pp.: 921-937, jul./ago 1992.
- [BON92b] Bonnett, A.H., "Cause and analysis of bearing failures in electrical motors”, en proceedings de: Petroleum and Chemical Industry Conference, pp.87-95, 1992.
- [BON93] Bonnett, A.H. "Cause and analysis of anti-friction bearing failures in AC induction motors”, en proceedings de: Pulp and Paper Industry Technical Conference, pp.36-46, 1993.
- [BON96] Bonnett A. H., “Analysis of the impact of pulse-width modulated inverter voltage waveforms on AC induction motors”, IEEE Transactions on Industry Applications, vol. 32, n° 2, pp.: 386–392, mar./abr. 1996.
- [BON97] Bonnett, A.H., “Quality and reliability of energy efficient motors”, IEEE Industry Applications Magazine, vol. 3, n° 1, pp.: 22-31, ene./feb. 1997.
- [BON98] Bonnett, A.H. “Cause, analysis and prevention of motor shaft failures”, en proceedings de: Pulp and Paper Industry Technical Conference, pp.166-180, 1998.
- [BON99] Bonnett, A.H., “Understanding motor shaft failures”, IEEE Industry Applications Magazine, vol.5, n° 5, pp. 25-41, set./oct. 1999.
- [BON00] Bonnett, A.H., “Root cause AC motor failure analysis with a focus on shaft failures”, IEEE Transactions on Industry Applications, vol.36, n° 5, pp.: 1435-1448, set./oct. 2000.
- [BON12] Bonnett, A.H., “Root Cause Methodology for Induction Motors: A Step-by-Step Guide to Examining Failure”, IEEE Industry Applications Magazine, vol. 18, n°.6, pp.: 50-62, nov./dic. 2012.

Referencias

- [BOS05] Bossio G. R., Angelo C. H. D., Garcia G. O., Solsona J. A., y Valla M. I., "Effects of rotor bar and end-ring faults over the signals of a position estimation strategy for induction motors", IEEE Transactions on Industry Applications, vol. 41, n° 4, pp.: 1005–1012, jul./ago. 2005.
- [BOS09] Bossio, G.R., De Angelo, C.H., Pezzani, C.M., Bossio, J.M. y Garcia, G.O. , "Evaluation of harmonic current sidebands for broken bar diagnosis in induction motors", en proceedings de: IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives, 2009.
- [BRI08a] Briz F., Degner M.W., Garcia P., y Diez A. B., "High-frequency carrier signal voltage selection for stator winding fault diagnosis in inverter-fed AC machines," IEEE Transaction in Industrial Electronics, vol. 55, n° 12, pp.: 4181–4190, dic. 2008.
- [BRI08b] Briz F., Degner M.W., Garcia P. y Bragado D., "Broken Rotor Bar, Detection in line-fed induction machines using complex wavelet analysis of startup transients", IEEE Transactions on Industry Applications vol.44, n° 3, pp.: 760-768, 2008.
- [BRI11] Briscoea E. y Feldmanb J. "Conceptual complexity and the bias/variance tradeoff" Cognition vol.118, pp.: 2–16, 2011.
- [BRO88] van der Broeck, H.W. y Skudelny, H.C., "Analytical analysis of the harmonic effects of a PWM AC drive", IEEE Transactions on Power Electronics, vol.3, n° 2, pp.216-223, abr. 1988.
- [BRU06] Bruzzese C., Honorati O., Santini E. y Sciunnache D., "New Rotor Fault, Indicators for squirrel cage induction motors", en proceedings de: 41st IEEE IAS Annual Conference of Industry Applications, pp.: 1541-1548, 2006.
- [BUR96] Burnett R., Watson J.F. y Elder S., "The application of modern signal processing techniques for use in rotor fault detection and location within three phase induction motors", Signal Processing vol.49, n° 1, pp.: 57-70, 1996.
- [CAL07] Calis H. y Cakir A., "Rotor bar fault diagnosis in three phase induction motors by monitoring fluctuations of motor current zero crossing instants", Electrical Power System Research vol.77 n° 5-6, pp.: 385-392, 2007.
- [CAL08] Calis H. y Cakir A., "Experimental study for sensorless broken bar detection in induction motors", Energy Conversion and Management vol.49, n° 4, pp.: 854-862, 2008.
- [CAR88] Cardoso A.J.M., y Saraiva E.S., "On-line diagnostics of three-phase induction motors by Park's vector", en proceedings de: International Conference on Electrical Machines (ICEM), vol. 3, pp.: 231-234, 1988.
- [CAR95] Cardoso A.J.M., Cruz S.M.A., Carvalho J.F.S. y Saraiva E.S., "Rotor cage fault diagnosis in three-phase induction motors by Park's vector approach" en proceedings de: Conference of Industry Applications, pp.: 642-646, 1995.
- [CAS02] Castillo, E., Fontenla-Romero, O., Alonso-Betanzos, A. y Guijarro-Berdinas, B., "A Global Optimum Approach for One-Layer Neural Networks", Neural Computation, vol.14, n° 6, pp. 1429-1449, 2002.
- [CAS97] Castellon, J., Bouquart, J., Reboul, J.P., y Toureille, A. , "A new tool to study the ageing of the winding insulation of electrical machines", en proceedings de: IEEE Conference on Electrical Insulation and Dielectric Phenomena, 1997.
- [CAS06] Castillo, E., Guijarro-Berdinas, B., Fontenla-Romero, O. y Alonso-Betanzos, A.: "A Very Fast Learning Method for Neural Networks Based on Sensitivity Analysis". Journal of Machine Learning Research, vol.7, pp. 1159- 1182, 2006.
- [CHA05] Chang, G.W. y Shin-Kuan Chen, "An analytical approach for characterizing harmonic and interharmonic currents generated by VSI-fed adjustable speed

Referencias

- drives”, IEEE Transactions on Power Delivery, vol.20, n°4, pp.: 2585- 2593, oct. 2005.
- [CHA06] Chaudhury, S.B. y Gupta, S., "Online Identification Of AC Motor Misalignment Using Current Signature Analysis and Modified K-Mean Clustering Technique”, en proceedings de: IEEE International Conference on Industrial Technology (ICIT) pp.2331-2336, dic. 2006.
- [CHE98] Cherkassky, V. y Mulier, F., “Learning from Data: Concepts, Theory, and Methods”, Wiley, New York, 1998.
- [CHO98] Cho, D.-H. y Kim, K.-J., “Modelling of electromagnetic excitation forces of small induction motor for vibration and noise analysis”, IEE Proceedings on Electric Power Applications, vol.145, no.3, pp.199-205, may. 1998.
- [CHR97] Ronald C., “Log-linear models and logistic regression” 2nd edition, Springer-Verlag 1997.
- [CLA11] Claude S., Webb G. I. (Eds.) “Encyclopedia of Machine Learning” Springer Science+BusinessMedia, LLC ISBN 979-0-387-30768-8, 2011.
- [CLI12] Climente-Alarcón, V., “Aportación al mantenimiento predictivo de motores de inducción mediante modernas técnicas de análisis de la señal”, tesis doctoral, Universidad Politécnica de Valencia, 2012.
- [COL98] Collis W.B., White P.R. y Hammond J.K., “Higher order spectra: The bispectrum and trispectrum”, Mechanical Systems and Signal Processing vol.12, n° 3, pp.: 375-395, 1998.
- [COM01] Combastel C., Lesecq S., Petropol S. y Gentil S., “Model-based and wavelet approaches to induction motor on-line fault detection”, Control Engineering Practice, vol.10, n° 5, pp.: 493-509, may, 2002.
- [CRU99] Cruz S.M.A. y Cardoso A.J.M., “Rotor cage fault diagnosis in three-phase induction motors by the total instantaneous power spectral analysis”, en proceedings de: 34th IAS Annual Meeting Conference, pp.: 1929-1934, 1999.
- [CRU00] Cruz S.M.A., Cardoso A. J. M., “Rotor cage fault diagnosis in three-phase induction motors by extended Park’s vector approach”, Electric Power Components and Systems vol.28, n° 4, pp.: 289-299, 2000.
- [CRU01] Cruz S.M.A. y Cardoso A.J.M., “Discriminating between rotor asymmetries and time-varying loads in three-phase induction motors”, en proceedings de: International Congress Condition Monitoring Diagnostic Engineering Manage, pp.: 319-327, 2001.
- [CUN07] Cunha, C.C.M., Filho, B.J.C. y Lyra, R.O.C. , “Detection of rotor faults in torque controlled induction motor drives”, en proceedings de: European Conference on Power Electronics and Applications, pp.1-10, set. 2007.
- [CUP04] Cupertino F., Vanna E., Salvatore L. y Stasi S., “Analysis techniques for detection of IM broken rotor bar after supply disconnection”, IEEE Transactions on Industry Applications vol.40, n° 2, pp.: 526-533, 2004.
- [CYB89] Cybenko, G. “Approximation by superposition of a sigmoidal function”, Mathematics of Control, Signals and Systems, vol.2, pp. 304-314, 1989.
- [DAU90] Daubechies I., “The wavelet transform, time-frequency localization and signal analysis”, IEEE Transactions on Information Theory vol.36, n° 5, pp.: 961-1005, 1990.
- [DEA10] De Angelo C.H., Bossio G.R. y Garcia G.O., “Discriminating broken rotor bar from oscillating load effects using the instantaneous active and reactive powers”, IET Electric Power Applications vol.4, n° 4, pp.: 281-290, 2010.

Referencias

- [DEL82] Deleroi, W. "The Squirrel Cage Motors with Broken Bar in the Rotor - Physical phenomena and their experimental Assessment", Proceedings of International Conference of Electrical Machines, pp.: 767-770, 1982.
- [DEN83] Dennis, J. E. y Schnabel, R. B., "Numerical Methods for Unconstrained Optimization and Nonlinear Equations" Prentice-Hall, Englewood Cliffs, N J, 1983.
- [DIC62] Dickinson, W.H., "Report on Reliability of Electric Equipment in Industrial Plants", AIEE Transactions , Part II, vol 81, jul. 1962.
- [DID03a] Didier G., Razik H. y Rezzoug A., "On the experiment detection of incipient rotor fault of an induction motor", en proceedings de: IEEE International Electric Machines and Drives Conference, vol. 2, pp.: 913-916, 2003.
- [DID03b] Didier G., Razik H., Caspary O. y Ternisien E., "Rotor Cage Fault Detection in Induction Motor using global modulation index on the Instantaneous Power Spectrum", en proceedings de: Symposium on Diagnostics for Electric Machines, Power Electronics and Drives, pp.: 104-109, 2003.
- [DID06] Didier G., Ternisien E., Caspary O. y Razik H., "Fault detection of broken rotor bars in induction motor using a global fault index", IEEE Transactions on Industry Applications vol.42, n° 1, pp.: 79-88, 2006.
- [DID07] Didier G., Ternisien E., Caspary O. y Razik H., "A new approach to detect broken rotor bars in induction machines by current spectrum analysis", Mechanical Systems and Signal Processing vol.21, n° 2, pp.: 1127-1142, 2007.
- [DON09] Dong M., Cheang T., y Chan S., "On-Line Fast Motor Fault Diagnostics Based on Fuzzy Neural Networks", Tsinghua Science & Technology, vol.14, n° 2, pp.: 225-233, abr. 2009.
- [DOU04] Douglas H., Pillay P. y Ziarani A., "A new algorithm for transient motor current signature analysis using wavelets", IEEE Transactions on Industry Applications vol.40, n° 5, pp.: 1361-1368, 2004.
- [DRI07] Drif M., Cardoso A.J.M., "Rotor cage fault diagnostics in three-phase induction motors, by the instantaneous non-active power signature analysis", en proceedings de: IEEE International Symposium on Industrial Electronics, pp.: 1050-1055, 2007.
- [DRI09] Drif M. y Cardoso A.J.M., "The use of the instantaneous-reactive-power signature analysis for rotor-cage-fault diagnostics in three-phase induction motors", IEEE Transactions on Industrial Electronics vol.56, n° 11, pp.: 4606-4614, 2009.
- [DUQ02a] Duque-Pérez O y Pérez-Alonso M., "Fiabilidad de los motores de inducción. Estudios históricos y necesidad de actualización (I)", Gestión de Activos Industriales. vol. 22, pp.: 36-41, mar./abr. 2002.
- [DUQ02b] Duque-Pérez O y Pérez-Alonso M., "Fiabilidad de los motores de inducción. Estudios históricos y necesidad de actualización (II)", Gestión de Activos Industriales. vol.23, pp.: 89-94, 2002, may. /jun. 2002.
- [DUQ04] Duque-Pérez O, Pérez-Alonso M., y Morinigo-Sotelo D., "Practical application of the spectral analysis of line current for the detection of mixed eccentricity in cage induction motors fed by frequency converter," en proceedings de: 16th International Conference on Electrical Machines (ICEM), Cracow, Poland, 2004.
- [DUQ04a] Duque-Pérez O, Pérez-Alonso M., y Morinigo-Sotelo D., "Fallos característicos de los motores de inducción. Fallos en el estator". Ingeniería y Gestión de Mantenimiento, vol. 34, pp.: 79 – 84, 2004.
- [DUQ04b] Duque-Pérez O, Pérez-Alonso M., y Morinigo-Sotelo D., "Fallos característicos de los motores de inducción. Fallos en el rotor", Ingeniería y Gestión de Mantenimiento. vol. 35, pp.: 74 – 79, 2004.

Referencias

- [DUQ04c] Duque-Pérez O, Pérez-Alonso M., y Morinigo D., “Fallos característicos de los motores de inducción. Fallos en rodamientos y eje”, *Ingeniería y Gestión de Mantenimiento*. vol. 36, pp.: 69 – 72, 2004.
- [DUQ05a] Duque O. y Perez M., “Motores de Inducción: Técnicas de Mantenimiento Preventivo”. Badajoz, España: Abecedario, 2005.
- [DUQ05b] Duque-Perez O., Perez-Alonso M., y Morinigo-Sotelo D., “Detection of bearing faults in cage induction motors fed by frequency converter using spectral analysis of line current”, en proceedings de: IEEE International Electric Machines and Drives Conference, EE.UU., pp. 17–22, may 2005.
- [DUQ10] Duque-Perez O., Morinigo-Sotelo D., Rodriguez-Carrascal, A., Garcia-Escudero, L.A. y Perez-Alonso, M., “Experimental identification of induction motor broken bar characteristic frequencies using a programmable power source”, en proceedings de: XIX International Conference on Electrical Machines (ICEM), pp.1-6, set. 2010.
- [DUQ11a] Duque-Perez, O., Morinigo-Sotelo, D. y Perez-Alonso, M., “Diagnosis of induction motors fed by supplies with high harmonic content using motor current signature analysis”, en proceedings de: International Conference on Power Engineering, Energy and Electrical Drives (POWERENG), pp.1-6, may 2011.
- [DUQ11b] Duque-Perez, O., Morinigo-Sotelo, D., Perez-Alonso, M., Rodriguez-Carrascal, A.y Garcia-Escudero, L.A., “Identification of eccentricity related-faults characteristic frequencies in induction motors using a programmable power source”, en proceedings de: IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics & Drives (SDEMPED), pp.468-473, set. 2011.
- [DUQ12a] Duque-Perez, O., Garcia-Escudero, L.A., Morinigo-Sotelo, D., Gardel-Sotomayor, P.E. y Perez-Alonso, M., “Condition monitoring of induction motors fed by Voltage Source Inverters. Statistical analysis of spectral data”, en proceedings de: XXth International Conference on Electrical Machines (ICEM), pp.2479-2484, 2-5 Spt. 2012.
- [DUQ12b] Duque-Perez, O., Morinigo-Sotelo, D. y Perez-Alonso, M.: “Detection of broken bars in railway induction motors fed by frequency converter using spectral analysis of line current”, *International Review of Modelling and Simulations*, vol. 5, n° 2, pp.: 959-966, abr. 2012.
- [ELD89] Elder S., Watson J.F. y Thomson W.T., “Fault detection in induction motors as a result of transient analysis”, en proceedings de: Fourth International Conference Electrical Machines and Drives, pp.: 182-186, 1989.
- [ELK92] Elkasabgy N.M., Eastham A.R. y Dawson G.E., “Detection of broken bars in the cage rotor on an induction machine”, *IEEE Transactions on Industry Applications* vol.28 n° 1, pp.: 165-171, 1992.
- [ELL71] Ellison A.J. y Yang S.J., “Effects of rotor eccentricity on acoustic noise from induction machines”, *Proceedings of the Institution of Electrical Engineers*, pp. 174-184, 1971.
- [ELT04] Eltabach M., Chahata A. y Zein I., “A comparison of external and internal methods of signal spectral analysis for broken rotor bars detection in induction motors”, *IEEE Transactions on Industrial Electronics* vol.51, n° 1, pp.: 107-121, 2004.
- [EPR85] EPRI, Life Expectancy or Motors in Mild Nuclear Plant Environments. EPRI REPORT NP-3887, feb. 1985.
- [ERT01] Ertunc HM, Loparo KA y Ocak H “Tool wear condition monitoring in drilling operations using hidden Markov models”, *International Journal of Machine Tools and Manufacture* vol.41, pp.: 1363–1384, 2001.

Referencias

- [EXP13] Exploración de Datos: Introducción a la estadística descriptiva, Recursos Educativos para los Profesores de la Universidad Católica de Valparaíso, disponible online: <http://www.ucv.cl/web/estadistica/index.htm>, 2013.
- [FAI08] Faiz J. y Ebrahimi B.M., "A new pattern for detecting broken rotor bars in induction motors during start-up", *IEEE Transactions on Magnetics* vol.44, n° 2, pp.: 4673-4683, 2008.
- [FEL99] Feldman M. y Seibold S., "Damage diagnosis of rotors: Application of Hilbert transform and multihypothesis testing", *Journal of Vibration and Control* vol.5, n° 3, pp.: 421-442, 1999.
- [FER09] Fernandez J. C., Carbonero M., Gutierrez P. A. y Hervas C., "Ensembles de redes neuronales construidos mediante algoritmos híbridos multiobjetivo para optimizar la precisión y la sensibilidad" en proceedings de: VI Congreso Español sobre Metaheurísticas, Algoritmos Evolutivos y Bioinspirados, 2009.
- [FER92] Ferrah A., Bradley K.J. y Asher G.M., "An FFT-based novel approach to noninvasive speed measurement in induction motor drives", *IEEE Transactions Instrument Measurement* vol.41, n° 6, pp.: 797-802, 1992.
- [FIL92] Filippetti F., Martelli M., Franceschini G. y Tassoni C., "Development of expert system knowledge base to on-line diagnosis of rotor electrical faults of induction motors", en proceedings de: IEEE Industry Applications Society Annual Meeting, pp.: 92-99, 1992."
- [FIL95] Filippetti F., Franceschini G. y Tassoni C., "Neural networks aided on-line diagnostics of induction motor rotor faults", *IEEE Transactions on Industry Applications* vol.31 n° 4, pp.: 892-899, 1995.
- [FIL98] Filippetti F., Franceschini G., Tassoni C. y Vas P., "AI techniques in induction machines diagnosis including the speed ripple effect", *IEEE Transactions on Industry Applications* vol.34, n° 1, pp.: 98-108, 1998.
- [FIS36] Fisher, R. A. "The use of multiple measurements in taxonomic problems", en *Annals of Eugenics*, vol.7, pp.: 179-188, 1936.
- [FIS01] Fiser R. y Ferkolj S., "Application of Finite Element Method to Predict Damaged Induction Motor Performance," *IEEE Transaction on Magnetics*, vol. 37, n° 5, pp.: 3635-3639, set. 2001.
- [FON03] Fontenla-Romero, O., Erdogmus, D., Principe, J .C., Alonso-Betanzos, A. y Castillo, E.: "Linear least-squares based methods for neural networks learning" en proceedings de: Joint International Conference on Artificial Neural Networks And Neural Information, processing Lecture Notes in Computer Science, pp.: 84-91, 2003.
- [GAR11a] Garcia-Escudero LA, Duque-Perez O, Morinigo-Sotelo D, y Perez-Alonso M , "Robust condition monitoring for early detection of broken rotor bars in induction motors". *Expert Systems Applications* vol.38, pp.: 2653-2660", 2011.
- [GAR11b] Garcia-Escudero, L.A., Duque-Perez, O., Morinigo-Sotelo, D. y Perez-Alonso, M., "Robust multivariate control charts for early detection of broken rotor bars in an induction motors fed by a voltage source inverter", en proceedings de: International Conference on Power Engineering, Energy and Electrical Drives (POWERENG), pp.1-6, 11-13 may. 2011.
- [GAR12] Gardel-Sotomayor, P., Morinigo-Sotelo, D., Duque-Perez, O., Perez-Alonso, M. y Garcia-Escudero, L.A. , "Neural network broken bar detection using time domain and current spectrum data", en proceedings de: XXth International Conference on Electrical Machines (ICEM), pp.: 2492-2497, set. 2012.

Referencias

- [GAY79] Gaydon B.E., "An instrument to detect induction motor rotor circuit defects by speed fluctuation measurements", en proceedings de: Electric Test and Measuring Equipment Conference, pp.: 5-8, 1979.
- [GAY95] Gaylard A., Meyer A. y Landy C., "Acoustic evaluation of faults in electrical machines", en proceedings de: Seventh International Conference on Electrical Machines and Drives, pp.: 147-150, 1995.
- [GER07] Germen E., Gökhan Ece D., y Nezh Gerek O, "Self Organizing Map (SOM) Approach for Classification of Mechanical Faults in Induction Motors" F. Sandoval et al. (Eds.): IWANN 2007, LNCS 4507, pp.: 855-861, 2007. "
- [GHA10] Ghate V. y Dudul S., "Optimal MLP neural network classifier for fault detection of three phase induction motor", Expert Systems with Applications, vol. 37, n° 4, pp.: 3468-3481, abr. 2010.
- [GIL01] Gil Flores J., García Jiménez E. y Rodríguez Gómez G., "Análisis Discriminante" Ed. La Muralla, 2001.
- [GRO00] Grotzbach, M.y Redmann, R., "Line current harmonics of VSI-fed adjustable-speed drives", IEEE Transactions on Industry Applications, vol.36, n°2, pp.: 683-690, mar/abr 2000.
- [GU06] Gu F., Yesilyurt I., Li Y., Harris G. y Ball A., "An investigation of the effects of measurement noise in the use of instantaneous angular speed for machine diagnosis", Mechanical Systems and Signal Processing vol.20, n° 6, pp.: 1444-1460, 2006.
- [GUN09] Gunal S, Ece DG, Gerek O. N., "Induction machine condition monitoring using notch-filtered motor current". Mechanical Systems Signal Processing vol.23, pp.: 2658-2670, 2009.
- [HAG94] Hagan, M. T . y Menhaj, M., "Training feedforward networks with the Marquardt algorithm", IEEE Transactions on Neural Networks, vol.5, n° 6 , pp. 989- 993, 1994.
- [HAJ01] Haji M. y Toliyat H. A., "Pattern recognition: A technique for induction machines rotor broken bar detection", IEEE Transactions Energy Conversion vol.16, n° 4, pp.: 312-317, 2001.
- [HAN90] Hansen L. K. y Salamon P., "Neural Network Ensembles" IEEE Transactions On Pattern Analysis And Machine Intelligence, vol. 12, n° 10, oct. 1990.
- [HAN07] Han T., Yang B.S. y Yin Z.J., "Feature-based fault diagnosis system of induction motors using vibration signal", Journal of Quality in Maintenance Engineering vol.13 n° 2, pp.: 163-175, 2007.
- [HAR82] Hargis C., Gaydon B. y Kamash K., "The detection of rotor defects in induction motors", en . proceedings de: IEE Conference Electrical Machine, pp. 216-220, 1982.
- [HAY89] Haynes H.D. y Eissenberg D.M., "Motor current signature analysis", The Oak Ridger, dic. 1989.
- [HAY90] Haynes H.D., Kryter R.C. y Stewart B.K., "Use of motor current signature analysis at The EPRI M&D Center", en proceedings de: EPRI Incipient Failure Detection Conference: Predictive Maintenance, 1990.
- [HED07a] Hedayati-Kia S., Henao H. y Capolino G.A., "A. High-Resolution, Frequency estimation method for three-phase induction machine fault detection", IEEE Transactions on Industrial Electronics vol.54, n° 4, pp.: 2305-2314, 2007.
- [HED07b] Hedayati-Kia S., Henao H. y Capolino G.A., "Digital signal processing for induction machines diagnosis: A Review", en proceedings de: 33rd Annual Conference of the IEEE Industrial Electronics Society, pp.: 1155-1162, 2007.

Referencias

- [HED09] Hedayati-Kia S., Henao H. y Capolino G.A., “Diagnosis of broken-bar fault in induction machines using discrete wavelet transform without slip estimation”, IEEE Transactions on Industry Applications vol.45, n° 4, pp.: 1395-1404, 2009.
- [HEN03] Hedayati-Kia S., Demian C. y Capolino G.A., “A. Frequency-Domain, Detection of stator winding faults in induction machines using an external flux sensor”, IEEE Transactions on Industry Applications vol.39, n° 5, pp.: 1272-1279, 2003.
- [HER09] Herrero A. “Análisis De Los Parámetros Modales De Una Unión Soldada”, Proyecto Fin De Carrera, Ingeniería Técnica Industrial: Mecánica Universidad Carlos III De Madrid, 2009.
- [HIR94] Hirvonen R., “On line condition monitoring of defects in squirrel cage motors”, en proceedings de: International Conference of Electrical Machine (ICEM), pp.: 267.272, 1994.
- [HOL03] Holmes D. G. y Lipo T. A., “Pulse width modulation for power converters. Principles and practice”, Wiley-Interscience, IEEE Press, New Jersey, EE.UU., 2003.
- [HOP82] Hopfield, J. J. “Neural Networks and physical systems with emergent collective computational abilities”, Proceedings of the National Academy of Sciences, EE.UU. vol.79, n° 8, pp.: 2554-2558, 1982.
- [HOS00] Hosmer D. W, y Lemeshow S., “Applied Logistic Regression” Second Edition, John Wiley & Sons, 2000.
- [HSU92] Hsu J.S., Woodson H. H. y Weldon W. F., “Possible errors in measurement of air gap torque pulsations of induction motors”, IEEE Transactions on Energy Conversion vol.7, n° 1, pp.: 202-208, 1992.
- [HSU95] Hsu J. S., “Monitoring of defects in induction motors through air-gap torque observation”, IEEE Transactions on Industry Applications vol.31, n° 5, pp.: 1016-1021, 1995.
- [HU07] Hu Q, He Z, Zhang Z y Zi Y “Fault diagnosis of rotating machine based on improved wavelet package transform and SVMs ensemble”, Mechanical Systems and Signal Processing vol.21, pp.: 688–705, 2007.
- [HUA07] Huang X., Habetler T.G., Harley R.G. y Wiedenbrug E.J., “Using a surge tester to detect rotor eccentricity faults in induction motors”, IEEE Transactions on Industry Applications vol.43, n° 5, pp.: 1183-1190, 2007.
- [HUB94] Huberly, C.J., “Applied discriminant analysis” John Wiley & Sons, New York, 1994.
- [HUR96] Hurst H.D. y Habetler T.G., “Sensorless speed measurement using current harmonic spectral estimation in induction machine drives”, IEEE Transactions on Power Electronics vol.11, n° 1, pp.: 66-73, 1996.
- [HUR97] Hurst K.D. y Habetler T.G., “A comparison of spectrum estimation techniques for sensorless speed detection in induction machines”, IEEE Transactions on Industry Applications vol.33, n° 4, pp.: 898-905, 1997.
- [HUS88] Hush, D. R. y Salas, J. M., “Improving the learning rate of back-propagation with the gradient reuse algorithm” en proceedings de: IEEE Conference of Neural Networks, vol.1, pp. 441- 447 , 1988.
- [IEE85] IEEE “Report Large Motor Reliability Survey of Industrial and Commercial Installations”. Part I. May 84, IEEE Trans. Ind. Appli. Jul/Aug 1985. Part II. Sep 84. IEEE Transaction on Industrial Applications, vol.21, n° 4, jul/ago. 1985.
- [IEE87] IEEE, “Report Large Motor Reliability Survey of Industrial and Commercial Installations”. Part III. Sep 86. IEEE Transaction on Industrial Applications, vol.23, n° 1 , ene./feb. 1987.

Referencias

- [ISA09] Isasi P., Galván I. M., “Redes neuronas artificiales: un enfoque práctico” Pearson Educación, 2009.
- [JAC88] Jacobs, R. A., “Increased Rates of Convergence Through Learning Rate Adaptation”, *Neural Networks*, vol.1, n° 4 , pp. 295- 308, 1988.
- [JAC99] Jacobina, C.B. ,de Rossiter Correa, M.B., da Silva, E.R.C. y Lima, A.M.N., “Induction motor drive system for low-power applications,” *IEEE Transactions on Industry Applications*, vol.35 ,n° 1, pp: 52 – 61, ene./feb. 1999.
- [JAI96] Jain, A.K., Mao J. y Mohiuddin, K.M., "Artificial neural networks: a tutorial", *Computer* , vol.29, n° 3, pp. 31-44, mar. 1996.
- [JAK03] Jaksch I., “Faults diagnosis of three phase induction motors using envelope analysis”, en proceedings de: *Symposium on Diagnostics for Electric Machines, Power Electronics and Drives*, 2003.
- [JAN95] Jansen P.L. y Lorenz R.D., “Transducerless position and velocity estimation in induction and salient AC machines”, *IEEE Transactions on Industry Applications* vol.31, n° 2, pp.: 240-247, 1995.
- [JAR06] Jardine A.K.S., Lin D. y Banjevic D., “A review on machinery diagnostics and prognostics implementing condition-based maintenance”, *Mechanical Systems and Signal Processing* vol.20, n° 7, pp.: 1483-1510, 2006.
- [JUN06] Jung J.-H., Lee J.J. y Kwon, B. H., "Online Diagnosis of Induction Motors Using MCSA", *IEEE Transactions on Industrial Electronics*, vol.53, n°6, pp.: 1842-1852, dic. 2006.
- [KAM10] Kaminski, M., Kowalski, C.T. y Orłowska-Kowalska, T., “General Regression Neural Networks as Rotor Fault Detectors of the Induction Motor”, en proceedings de: *IEEE International Conference on Industrial Technology*, pp.: 1239 -1244, 2010.
- [KEN83] Kendall, M., Stuart, A. y Ord, D. K. “The advanced theory of statistics. Volume 3: Design and analysis, and time-series”. Charles Griffin & Company Londres.1983.
- [KHE09] Khezzar A., Oumaamar M.E.K., Hadjami M., Boucherma M. y Razik H., “Induction motor diagnosis using line neutral voltage signatures”, *IEEE Transactions on Industry Applications* vol.56, n° 11, pp.: 4581-4591, 2009.
- [KIA06] Kia S.H., Mabwe A.M., Henao H. y Capolino G.A., “Wavelet based instantaneous power analysis for induction machine fault diagnosis”, en proceedings de: *32nd Annual Conference on IEEE Industrial Electronics, IECON*, pp. 1229-1234, 2006.
- [KIN10a] King G., Tarbouchi M. y McGaughey D., “Current signature analysis of induction machine rotor faults using the fast orthogonal search algorithm”, en proceedings de: *Fifth IET International Conference on Power Electronics, Machines and Drives*, pp 1-5, 2010.
- [KIN10b] King G., Tarbouchi M. y McGaughey D., “Rotor fault detection in induction motors using the fast orthogonal search algorithm”, en proceedings de: *IEEE International Symposium on Industrial Electronics*, pp.: 2621-2625, 2010.
- [KLE02] Kleinbaum D. G., Klein M. “Logistic Regression A Self-Learning Text” Second Edition. Springer, 2002.
- [KLI88] Kliman G.B., Koegl R.A., Stein J., Endicott R.D. y Madden M.W., “Noninvasive detection of broken rotor bars in operating induction motors”, *IEEE Transactions on Energy Conversion* vol.3, n° 4,pp.: 873-879, 1988.
- [KLI91] Kliman G.B., “Spectral analysis of induction motor current to detect rotor faults with reduced false alarms”, U.S. Patent 4049815, 1991.
- [KOH99] Kohler J.L., Sottile J. y Trutt F.C., “Condition-based maintenance of electric machines”, en proceedings de: *IEEE Industrial Applications Conference*, pp.: 205-211, 1999.

Referencias

- [KOW03] Kowalski C. T., Orłowska-Kowalska T., “Neural networks application for induction motor faults diagnosis”, *Mathematics and Computers in Simulation*, vol.63, n° 3-5, pp.: 435-448, nov. 2003.”
- [KRA02] Kral C., Pirker F. y Pascoli G., “Detection of rotor faults in squirrel-cage induction machines at stand still for batch tests by means of the Vienna monitoring method”, *IEEE Transactions on Industry Applications* vol.38, n° 3, pp.: 618-624, 2002.
- [KRA03] Kral C., Habetler T.G., Harley R.G., Pirker F., Pascoli G., Oberguggenberger y Fenz C.J.M., “A comparison of rotor fault detection techniques with respect to the assessment of fault severity”, en *proceeding de: Symposium on Diagnostics for Electric Machines, Power Electronics and Drives*, Atlanta, EE.UU., pp. 24-26, 2003.
- [KRA05] Kral C., Pirker F. y Pascoli G., “Model-based detection of rotor faults without rotor position sensor: The sensorless Vienna monitoring method”, *IEEE Transactions on Industry Applications* vol.41, n° 3, pp.: 784-789, 2005.
- [LAC02] Jack L.B. y Nandi A.K., “Fault detection using support vector machines and artificial neural networks, augmented by genetic algorithms”, *Mechanical Systems and Signal Processing* vol.16, pp.:373–390, 2002.
- [LAC67] Lachenbruch, P.A. “An almost unbiased method of obtaining confidence intervals for the probability of misclassification in discriminant analysis”, en *Biometrics*, vol.23, pp.: 639-645, 1967.
- [LAU10] Laughman C., Leeb S., Norford L., Shaw S. y Armstrong P., “Mitsubishi Electric Research Laboratories A Park Transform-Based Method for Condition Monitoring of Three-Phase Electromechanical Systems” TR2010-010, disponible online en: <http://www.merl.com/reports/docs/TR2010-010.pdf> , mayo 2010.
- [LEC98] Lecun, Y., Bottou, L., Orr, G.B. y Moller, K.-R., “Efficient BackProp.” en: G.B. Orr y K.R. Muller (Eds.), *Neural Networks: Tricks of the trade*, n° 1524 en LNCS. Springer-Verlag, 1998.
- [LEE09] Lees A.W., Sinha J.K. y Friswell M.I. “Model-based identification of rotating machines” *Mechanical Systems and Signal Processing*, vol.23, n° 6, pp.: 1884-1893, ago. 2009.
- [LEI09] Leija L. “Métodos de procesamiento avanzado e inteligencia artificial en sistemas sensores y biosensores” Editorial Reverté S.A. ISBN 978-84-191-8013-8, 2009.
- [LI06] Li W. y Mechefske C.K., “Detection of induction motor faults: A comparison of stator current, vibration and acoustic methods”, *Journal of Vibration and Control* vol.12, n° 2, pp.: 165-188, 2006.
- [LIA03] Liang B., Iwnicki S.D. y Ball A.D., “Asymmetrical stator and rotor faulty detection using vibration, phase current and transient speed analysis”, *Mechanical Systems and Signal Processing* vol.17, n° 4, pp.: 857-869, 2003.
- [LIU04] Liu Z., Zhang X., Yin X. y Zhang Z., “Rotor cage fault diagnosis in induction motors based on spectral analysis of current Hilbert modulus”, en *proceedings de: IEEE Power Engineering Society General Meeting*, pp.1500-1503, 2004.
- [LIU12] Liu Y. W., “Hilbert Transform and Applications, Fourier Transform Applications”, Dr Salih Salih (Ed.),. Disponible online en: <http://www.intechopen.com/books/fourier-transform-applications/hilbert-transform-and-applications>, 2012.
- [LOP08] López R. y Fernández J. M., “Las Redes Neuronales Artificiales. Fundamentos teóricos y aplicaciones prácticas” Gesbiblio ,2008.
- [LOU11] Loutas TH, Roulias D, Pauly E y Kostopoulos V “The combined use of vibration, acoustic emission and Oil debris on-line monitoring towards a more effective

Referencias

- condition monitoring of rotating machinery”, *Mechanical Systems and Signal Processing* vol.25, pp.: 1339-1352, 2011.
- [LU08] Lu B. y Paghda M., “Induction motor rotor fault diagnosis using wavelet analysis of one-cycle average power”, en *proceedings de: IEEE Applied Power Electronics Conference and Exposition*, pp.: 1113-1118, 2008.
- [MAH36] Mahalanobis P.C., “On the generalised distance in statistics”, *Proceedings of the National Institute of Science of India* vol.12, 1936.
- [MAI92] Maier R., “Protection of squirrel-cage induction motor utilizing instantaneous power and phase information”, *IEEE Transactions on Industry Applications* vol.28, pp.: 376-380, 1992.
- [MAR89] Marple S.L., “*Digital Spectral Analysis with Applications*”, Prentice Hall, Englewood Cliffs, NJ, 1989.
- [MAR99] Marple Jr. L., “Computing the discrete-time analytic signal via FFT,” *IEEE Transaction on Signal Processing*, vol. 47, n° 9, pp.: 2600–2603, set. 1999.
- [MAR07] Martín Q., Cabero M. T. y Santana Y. “*Tratamiento estadístico de datos con SPSS. Prácticas resueltas y comentadas*”, ISBN: 9788497325530, 2007.
- [MAR12] Marwala T., “*Condition Monitoring Using Computational Intelligence Methods, Applications in Mechanical and Electrical Systems*”, ISBN 978-1-4471-2379-8 Springer-Verlag London Limited, 2012.
- [MAT10] Matic, D., Kulic, F., Climente-Alarcon, V. y Puche-Panadero, R. “Artificial Neural Networks Broken Rotor Bars Induction Motor Fault Detection”, en *proceedings de: 10th Symposium on Neural Network Applications in Electrical Engineering (NEUREL)*, pp.: 49- 53 , 2010.
- [MCC43] McCulloch, W.S. y Pitts W., “A logical calculus of the ideas immanent in neural nets”, *Bulletin of Mathematics Biophysics* vol.5, pp.:115-137, 1943.
- [MCC97] McCully P. y Landy C., “Evaluation of current vibration signals for squirrel cage induction motors condition monitoring”, en *proceedings de: Eighth International IEE Conference on Electrical Machines and drives*, pp. 331-355, 1997.
- [MEH07] Mehla N. y Dahiya R., “An approach of condition monitoring of induction motor using MCSA”, *International journal of systems applications, Engineering & Development* vol.1, n° 1, 2007.
- [MIA06] Miao Q, y Makis V “Condition monitoring and classification of rotating machinery using wavelets and hidden Markov models”, *Mechanical Systems and Signal Processing* vol.21, pp.: 840–855, 2006.
- [MIL99] Milimonfared J., Kelk H.M., Nandi S., Der Minassians A. y Toliyat H.A., “A novel approach for broken-rotor-bar detection in cage induction motors, *IEEE Transactions on Industry Applications* vol.35, n° 5, pp.: 1000-1006, 1999.
- [MIN69] Minsky M. y Papert S., “*Perceptrons: An Introduction to Computational Geometry*”, MIT Press, Cambridge, Mass., 1969.
- [MOL93] Moller, M. F., “A scaled conjugate gradient algorithm for fast supervised learning” *Neural Networks*, vol.6 , pp. 525- 533, 1993.
- [MOR10] Morinigo-Sotelo, D., Garcia-Escudero, L.A., Duque-Perez, O. y Perez-Alonso, M., “Practical Aspects of Mixed-Eccentricity Detection in PWM Voltage-Source-Inverter-Fed Induction Motors”, *IEEE Transactions on Industrial Electronics*, vol.57, n°1, pp.252-262, ene. 2010.
- [MUL03] Muller G. y Landy C., “A novel method to detect broken rotor bars in squirrel cage induction motors when interbar currents are present”, *IEEE Transaction on Energy Conversion* VOL.18, n° 1, pp.: 71-79, 2003.
- [NAM10] Nam K. H., “*AC Motor control and electric vehicle applications*”, CRC Press, EE.UU., 2010.

Referencias

- [NEL06] Nelwamondo FV, Marwala T y Mahola U., "Early classifications of bearing faults using hidden Markov models, Gaussian mixture models, mel-frequency cepstral coefficients and fractals", *International Journal of Innovative Computing Information and Control*, vol.2, pp.: 1281–1299, 2006.
- [NGU90] Nguyen, D. y Widrow, B., "Improving the Learning Speed of 2-Layer Neural Networks by Choosing Initial Values of the Adaptive Weights", en *proceedings de: International Joint Conference on Neural Networks*, pp. 21- 26, 1990.
- [NIU07] Niu G., Han T., Yang B.S. y Chiow-Tan A.C., "Multi-agent decision fusion for motor fault diagnosis", *Mechanical Systems and Signal Processing* vol.21, n° 3, pp.: 1285-1299, 2007.
- [NUÑ05] Núñez M. I , Salafranca L., Leiva D., Solanas A. y Sierra V. "Análisis estadístico mediante aplicaciones informáticas. SPSS, Statgraphics, Minitab y Excel" Publicacions I edicions de la Universitat de Barcelona, ISBN: 84-475-29, 2005.
- [ORR96] Orr, G. B. y Leen, T . K., "Using Curvature Information for Fast Stochastic Search", en: Jordan M.1., Mozer M.C. y Petsche T. (Eds.), *Neural Information Processing Systems*, vol. 9, pp. 606- 612. MIT Press, Cambridge, 1996.
- [OUM06] Oumaamar M.E.K., Babaa F., Khezzar A. y Boucherma M., "Diagnostics of broken rotor bars in induction machines using the neutral voltage", en *proceedings de: IEEE International Conference on Electrical Machines*, Chania, Greece, 2006.
- [OUM07] Oumaamar M.E.K., Khezzar A., Boucherma M., Razik H., Andriamalala R. y Baghli L., "Neutral voltage analysis for broken rotor bars detection in induction motors using Hilbert transform phase" en *proceedings de: Industry Applications Conference*, 2007.
- [PAL08] Palma J. T. y Marín R.. "Inteligencia Artificial. Técnicas, métodos y aplicaciones". McGraw-Hill/Interamericana de España, 2008.
- [PAM00] Pampel F. C. "Logistic regression. A Primer (Quantitative Applications in the Social Sciences)". Sage Publications, 2000.
- [PAR05] Pardo A y Ruiz A., "SPSS 10. Guía para el análisis de datos". Madrid, España. Universidad Autónoma de Madrid, 569 p., 2005
- [PAY02] Payne B.S., Ball A. y Gu F., "Detection and Diagnosis on Induction Motor Faults using Statistical Measures", *International Journal of Condition Monitoring and Diagnostics Engineering Management*, vol. 5, n° 2, pp.: 5-19, abr. 2002."
- [PEN01a] Penrose H.W., y Jette J., "Static motor circuit analysis: An introduction to theory and application", *IEEE Electrical Insulation Magazine* vol.16, n° 4, pp.: 6-10, 2000.
- [PEN01b] Penrose H.W., "Evaluation of electric motor condition using motor circuit analysis", en *proceedings de: Conference Insulation Electrical Manufacturing Coil Winding*, pp.: 335-340, 2001. "
- [PEN02] Penrose H.W., "Motor circuit analysis standards", *MCA Newsletter* , 2002.
- [PEN03] Penrose H.W., "Estimating motor life using motor circuit analysis predictive measurements", en *proceedings de: Electrical Insulation Conference and Electrical Manufacturing & Coil Winding Technology Conference*, pp.: 451""454, 2003.
- [PEN04a] Penrose H.W., "Estimating motor life using motor circuit analysis predictive measurements: Part 2", en *proceedings de: IEEE International Symposium on Electrical Insulation*, Indianapolis, EE.UU., pp.: 15-17, 2004.
- [PEN04b] Peng Z.K. y Chu F.L., "Application of the wavelet transform in machine condition monitoring and fault diagnostics: A review with bibliography", *Mechanical Systems and Signal Processing* vol.18, n° 2, pp.: 199-221, 2004.
- [PEN06a] Pennacchi P., Bachschmid N., Vania A., Zanetta G.A. y Gregori L., "Use of modal representation for the supporting structure in model-based fault

Referencias

- identification of large rotating machinery: Part 1—theoretical remarks”, *Mechanical Systems and Signal Processing* vol.20, n° 3, pp.: 662–681, 2006.
- [PEN06b] Pennacchi P., Bachschmid N., Vania A., Zanetta G.A. y Gregori L., “Use of modal representation for the supporting structure in model-based fault identification of large rotating machinery: Part 2—application to a real machine”, *Mechanical Systems and Signal Processing* vol.20, n° 3, pp.: 682–701, 2006.
- [PEN94] Penman J., Sedding H.G., Lloyd B.A., y Fink W.T., “Detection and location of interturn short circuits in the stator windings of operating motors”, *IEEE Transactions on Energy Conversion* vol.9, n° 4, pp.: 652-658, 1994.
- [PEÑ02] Peña D., “Análisis de datos multivariantes” McGraw-Hill, 2002.
- [PET12] Petkovic M., Rapaic M. R., Jelcic Z. D. y Pisano A., “On-line adaptive clustering for process monitoring and fault detection”, *Expert Systems with Applications*, vol.39, n° 11, pp.: 10226-10235, set. 2012.
- [PIC12] Picazo-Rodenas, M.J., Royo, R., Antonino-Daviu J. y Roger-Folch, J., "Use of infrared thermography for computation of heating curves and preliminary failure detection in induction motors" en proceedings de: XXth International Conference on Electrical Machines (ICEM), Marsella Francia, 2012.
- [PIN01] Pino-Diez R., Gómez A. y Martínez N., "Introducción a la inteligencia artificial: sistemas expertos, redes neuronales artificiales y computación evolutiva" Universidad de Oviedo, servicio de publicaciones, 2001.
- [PIN09] Pineda-Sanchez M., Riera-Guasp M., Antonino-Daviu J. A., Perez-Cruz J., Roger-Folch J. y Puche-Panadero R., “Instantaneous Frequency of the Left Sideband Harmonic During the Start-Up Transient: A New Method for Diagnosis of Broken Bars” *IEEE Transactions On Industrial Electronics*, vol. 56, n° 11, nov. 2009.
- [PIN10] Pineda-Sánchez, M., Riera-Guasp, M., Antonino-Daviu, J. A., Roger-Folch, J., Perez-Cruz, J., Puche-Panadero, R. “Diagnosis of Induction Motor Faults in the Fractional Fourier Domain”, *IEEE Transactions on Instrumentation and Measurement*, vol.59 , n° 8, pp.: 2065 – 2075, 2010.
- [PLO05] Plotkin, Y., Stiebler, M. y Hofmeyer, D., "Sixth torque harmonic in PWM inverter-fed induction drives and its compensation," *IEEE Transactions on Industry Applications*, vol.41, n° 4, pp. 1067- 1074, jul./ago. 2005.
- [PON10] Pons-Llinares, J., Antonino-Daviu, J., Roger-Folch, J., Morinigo-Sotelo, D. y Duque-Perez, O., "Eccentricity diagnosis in Inverter - Fed Induction Motors via the Analytic Wavelet Transform of transient currents", en proceedings de: XIX International Conference on Electrical Machines, ICEM , pp.1-6, 6-8 Sept. 2010.
- [POV02] Povinelli R. J., Bangura J. F., Demerdash N. A. y Brown R. H., “Diagnostic of Bar and End-Ring Connector Breakage Faults in Poly-phase Induction Motors Through a Novel Dual Track of Time-Stepping Coupled FE-State Space Modelling,” *IEEE Transactions on energy Conversion*, vol. 17, n° 1, pp. 39-46, mar. 2002.
- [POW77] Powell, M. J. D., “Restart procedures for the conjugate gradient method”, *Mathematical Programming*, vol. 12, pp. 241- 254, 1977.
- [PUC09] Puche-Panadero R., Pineda-Sanchez M., Riera-Guasp M., Roger-Folch J., Hurtado-Perez E. y Perez-Cruz J., "Improved Resolution of the MCSA Method Via Hilbert Transform, Enabling the Diagnosis of Rotor Asymmetries at Very Low Slip," *IEEE Transactions on Energy Conversion*, vol.24, n° 1, pp.52-59, mar. 2009.
- [PUR05] Purushotham V, Narayanana S y Prasad S. “Multi-fault diagnosis of rolling bearing elements using wavelet analysis and hidden Markov model based fault recognition”. *NDT&E International Journal*, vol.38, pp.: 654–664, 2005.

Referencias

- [QIN07] Qing H. y Dong-Mei D. "Fault diagnosis of induction motor using neural networks", International Conference on Machine Learning and Cybernetics, pp.: 1090–1095, 2007
- [RAF04] Rafimanzelat M. R., Araabi B. N. y Khosroshahli E., "Induction Machine Broken Bar Detection Using Neural Networks Based Classification", en proceedings de: IEEE Conference on Cybernetics and Intelligent Systems Singapore, 1-3 December, 2004.
- [RAJ07] Rajagopalan, S., Aller, J.M., Restrepo, J.A., Habetler, T.G. y Harley, R.G., "Analytic-Wavelet-Ridge-Based Detection of Dynamic Eccentricity in Brushless Direct Current (BLDC) Motors Functioning Under Dynamic Operating Conditions", IEEE Transactions on Industrial Electronics, vol.54, n°3, pp.: 1410-1419, jun. 2007.
- [RAN09] Rangel-Magdaleno J., Romero-Troncoso R., Osornio-Rios R.A., Cabal-Yeppez E. y Contreras-Medina L.M., "Novel methodology for online half-broken bar detection on induction motors", IEEE Transactions on Instrumentation and Measurement vol.:58, n° 5, pp.: 1690-1698, 2009.
- [RAZ04] Razik H. y Didier G., "A novel method of induction motor diagnosis using the line-neutral voltage", en proceedings de: International Power Electronics and Motion Control Conference, Riga, Latvia, 2004.
- [RAZ09] Razik H., Henao H. y Carlson R., "An induction machine model including interbar currents for studying performances during transients and steady state", Electric Power Systems Research vol.79, n° 1, pp.: 181-189, 2009.
- [RAZ11] Razik H., "Handbook of asynchronous machine with variable speed", Wiley-ISTE, Londres, 2011.
- [REZ11] Rezazadeh M., Mariunn N., Hamiruce M., Misron N., "Rotor fault condition monitoring techniques for squirrel-cage induction machine: A review", Mechanical Systems and Signal Processing, vol. 25, n° 8, pp.: 2827–2848, nov. 2011.
- [RIC94] Rich E., Knight K. "Inteligencia Artificial" segunda edición, editorial McGraw-Hill, ISBN: 0-07-052263-4, 1994.
- [RID99] Riding the Reflected Wave to Improve Variable-Speed AC Motor Reliability. Rockwell Int. Corp. junio 1999. Disponible online.: <http://www.reliance.com/pdf/drives/whitepapers/D7722.pdf>
- [RIE09] Riera-Guasp M., Antonino-Daviu J. A., Roger-Folch J., y Molina-Palomares M. P., "The Use of the Wavelet Approximation Signal as a Tool for the Diagnosis of Rotor Bar Failures" IEEE Transactions On Industry Applications, vol. 44, n° 3, may/jun 2008.
- [ROD08] Rodriguez P.V.J., Negrea M. y Arkkio A., "A simplified scheme for induction motor condition monitoring", Mechanical Systems and Signal Processing vol.22, n° 5pp.: 1216-1236, 2008.
- [ROJ06] Rojas A y Nandi AK "Practical scheme for fast detection and classification of rolling-element bearing faults using support vector machines. Mechanical Systems and Signal Processing 20:1523–1536, 2006.
- [ROS62] Rosenblatt, F. "Principles of Neurodynamics: Perceptrons and the Theory of Brain Mechanisms", Spartan Books, Washington, D.C., 1962.
- [RUM86] Rumelhart D.E. y McClelland J.L., "Parallel Distributed Processing: Exploration in the Microstructure of Cognition", MIT Press, Cambridge, Mass., 1986.
- [RUM86] Rumelhart, D.E., G.E. Hinton y R.J. Williams, "Learning internal representations by error propagation", en Parallel Distributed Processing, ed. D. E. Rumelhart, J. L. McClelland y el PDP Research Group, 318-362. Cambridge , MA: MIT Press. , 1986.

Referencias

- [SAC93] Sachs N. "Failure Analysis of Mechanical Components", Maintenance Technology, disponible online: <http://www.maintenanceworld.com/articles/reliabilitycenter/failure-analysis-mechanical.htm> , 1993.
- [SAI02] Said M. S. N. y Benbouzid M. E. H., "H-G diagram based rotor parameters identification for induction motors thermal monitoring," IEEE Transaction on Energy Conversion., vol. 15, n° 1, pp. 14–18, mar, 2002.
- [SAL00] Salles G., Filippetti F., Tassoni C., Grellet G. y Franceschini G., "Monitoring of induction motor load by neural network techniques", IEEE Transactions on Power Electronics vol.: 15, n° 4, pp.: 762–768, 2000.
- [SAM03a] Samanta B, Al-Bushi K.R., "Artificial neural network based fault diagnostic of rolling elements bearing using time-domain features", Mechanical Systems and Signal Processing vol. 17 pp.: 317–328, 2003.
- [SAM03b] Samanta B., Al-Balushi K.R., Al-Araimi S.A., "Artificial neural networks and support vector machines with genetic algorithm for bearing fault detection", Engineering Applications of Artificial Intelligence, vol.16, n°7–8, pp.: 657-665 oct.-dic 2003.
- [SAS01a] Sasi A.B., Payne B., Gu F. y Ball A.D., "The exploitation of instantaneous angular speed for condition monitoring of electric motors", en proceedings de: 4th International Congress of Condition Monitoring and Diagnosis Engineering Management, Manchester, pp.: 311-318, 2001.
- [SAS01b] Sasi A.B., Payne B., York A., Gu F. y Ball A.D., "Condition monitoring of electric motors using instantaneous angular speed", en proceedings de: Maintenance and Reliability Conference (MARCON), Gatlinburg, TN, 2001.
- [SAS03] Sasi A.B., Soobramaney P., Gu F. y Ball A.D., "Diesel engine condition monitoring using instantaneous angular speed extracted from the alternator voltage output", en proceedings de: International Conference on Condition Monitoring, Oxford, UK, pp. 408-422, 2003.
- [SAS04] Sasi A.B., Gu F., Payne B. y Ball A.D., "Instantaneous angular speed monitoring of electric motors", Journal of Quality in Maintenance Engineering vol.10, n° 2, pp.: 123-135, 2004.
- [SAS06] Sasi A.B., Gu F., Li Y. y Ball A.D., "A validated model for the prediction of rotor bar failure in squirrel-cage motors using instantaneous angular speed", Mechanical Systems and Signal Processing vol.20, n° 7, pp.: 1572-1589, 2006.
- [SCH02] Schraudolph, N., "Fast Curvature Matrix-Vector Products for Second Order Gradient Descent", Neural Computation, vol.14, n° 7, pp.: 1723-1738, 2002.
- [SCH95] Schoen R., Lin B., Habetler T.G., Schalag J., Farag S., " An un-supervised online system for induction motor fault detection using stator current monitoring", IEEE Transactions on Industry Applications vol.31, n° 6, pp.: 1280-1286, 1995.
- [SEG02] Segui-Chilet S., Sánchez-Díaz C., Gimeno Fco. J. y Orts S. "Fundamentos Básicos de la Electrónica de Potencia" Editorial Universidad Politécnica de Valencia, 2002.
- [SEJ09] Sejdic E., Djurovic I. y Jiang J., "Time-frequency feature representation using energy concentration: An overview of recent advances", Digital Signal Processing vol.19, n° 1, pp.: 153-183, 2009.
- [SHE13] Shen C., Wang D., Konga F. y Tse P. W., "Fault diagnosis of rotating machinery based on the statistical parameters of wavelet packet paving and a generic support vector regressive classifier", Measurement vol.46, pp.: 1551–1564, 2013.
- [SIA04] Siau J., Graff A., Soong W. y Ertugrul N., "Broken bar detection in induction motors using current and flux spectral analysis", Australian Journal of Electrical and Electronics Engineering vol.1, n° 3, pp.: 171-177, 2004.

Referencias

- [SID05] Siddique A., Yadava G.S. y Singh B., "A review of stator fault monitoring techniques of induction motors", IEEE Transactions on Energy Conversion vol.:20, n° 1, pp.: 106-114, 2005.
- [SIL08] Silva A.M., Povinelli R.J. y Demerdash N.A.O., "Induction machine broken bar and stator short-circuit fault diagnostics based on three-phase stator current envelopes", IEEE Transactions on Industrial Electronics vol.55, n° 3, pp: 1310-1318, 2008.
- [SIL12] da Silva J. C., Saxena A., Balaban E., Goebel K. "A knowledge-based system approach for sensor fault modeling, detection and mitigation", Expert Systems with Applications, vol.39, n° 12, pp.: 10977-10989, 2012.
- [SKF94] SKF, Bearing failures and their causes. Disponible online en: www.skf.com/files/099926.pdf
- [SON09] Song-Manguelle, J., Schroder, S., Geyer, T., Ekemb, G. y Nyobe-Yome, J.-M., , "Prediction of mechanical shaft failures due to pulsating torques of variable frequency drives," en proceedings de: IEEE Energy Conversion Congress and Exposition, ECCE, pp.: 3469-3476, 20-24 set. 2009.
- [SON10a] Song-Manguelle, J., Nyobe-Yome, J.-M. y Ekemb, G., "Pulsating Torques in PWM Multi-Megawatt Drives for Torsional Analysis of Large Shafts," IEEE Transactions on Industry Applications, vol.46, n° 1, pp.: 130-138, ene./feb. 2010.
- [SON10b] Song-Manguelle, J., Sihler, C. y Schramm, S., "A general approach of damping torsional resonance modes in multi-megawatt applications," en proceedings de: IEEE Energy Conversion Congress and Exposition (ECCE, pp.772-779, 12-16 set. 2010.
- [STE86] Stevens, J., "Applied multivariate statistics for the social sciences". N. J., Hillsdale: Lawrence Erlbaum Associates, Pub.,1986.
- [STU92] Stuart G., Bienenstock E. y Doursat R. "Neural Networks and the Bias/Variance Dilemma" Neural Computation, vol.:4, pp.: 1 -58, 1992.
- [SUP05] Supangat R., Ertugrul N., Soong L., Gray D., Hansen C. y Grieger J., "Broken rotor bar fault detection in induction motors using starting current analysis", en proceedings de: European Conference on Power Electronics and Application, Alemania, 2005.
- [SUP07] Supangat R., Grieger J., Ertugrul N., Soong W.L., Gray D.A. y Hansen C., "Detection of broken rotor bar faults and effects of loading in induction motors during rundown", en proceedings de: IEEE International Electric Machines and Drives Conference, pp. 196-201, 2007.
- [SWE95] Sweeney P.J. y Randall R.B., "Sources of gear signal modulation", en proceedings de: Institution of Mechanical Engineers, pp.: 183-198, 1995.
- [TAB83] Tabachnick, B. G. y Fidell, L. S. "Using multivariate statistics". Harper & Row, Publishers, Nueva York, 1983.
- [TAK98] Takezawa Y., Itoh Y., Shimodera M., y Miya H., "Development of a portable diagnostic apparatus for coil insulators in low-voltage induction motors," IEEE Transactions on Dielectrics and Electrical Insulation, vol. 5, no. 2, pp.: 290-295, abr. 1998.
- [TAL02] Tallam R. J., Habetler T. G. y Harley R. G., "Transient Model for Induction Machines With Stator Winding Turns Faults," IEEE Transactions on Industry Applications, vol. 38, n° 3, pp.: 632-637, may./jun. 2002.
- [TAL03] Tallam R. M., Habetler T. G., y Harley R. G., "Stator winding turn-fault detection for closed-loop induction motor drives," IEEE Transactions on Industry Applications, vol. 39, n° 3, pp.: 720-724, may./jun. 2003.

Referencias

- [TAN08] Tang J. Z. y Wang Q.F. "Online fault diagnosis and prevention expert system for dredgers" *Expert Systems with Applications*, vol. 34, n° 1, pp.: 511-521, ene. 2008.
- [TAN99] Tandon N. y Choudhury A., "A review of vibration and acoustic measurement methods for the detection of defects in rolling element bearings", *Tribology International* vol.32, n° 8, pp.: 469-480, 1999.
- [TAV86] Tavner P. J., Gaydon B. G., y Ward D. M., "Monitoring generators and large motors," *IEE Proceedings Electric Power Applications*, vol. 133, n° 3, pp.: 169-180, May 1986.
- [THO83] Thomson W.T., Deans N.D., Leonard R.A. y Milne A.J., "Monitoring strategy for discriminating between different types of rotor defects in induction motors", en *proceedings de: University Power Engineering Conference*, pp.: 241-246, 1983.
- [THO95] Thorsen O.V. y Dalva M., "A survey of faults on induction motors in offshore oil industry, petrochemical industry, gas terminals, and oil refineries", *IEEE Transactions on Industry Applications* vol.31, n° 5, pp.: 1186-1196, 1995.
- [THO97a] Thosen, O.V. y Dalva, M. "Condition Monitoring Methods, Failure Identifications and Analysis for High Voltage Motors in Petrochemical Industry", en *proceedings de: Eighth International Conference on Electrical Machines and Drives*, 1997.
- [THO97b] Thomson W. T., Rankin D. y Dorrell D. G., "On-line current monitoring to diagnose air gap eccentricity an industrial case history of a large high- voltage three-phase induction motors", en *proceedings de: Electric Machines and Drives Conference Record*, pp.241-243, 1997.
- [THO98] Thomson W. T. y Barbour A., "On-line current monitoring and application of a finite element method to predict the level of static air gap eccentricity in three-phase induction motors", *IEEE Transactions on Energy Conversion* vol.13, n° 4, pp.: 347-357, 1998.
- [THO99a] Thorsen O.V. y Dalva M., "Failure identification and analysis for high-voltage induction motor in the petrochemical industry", *IEEE Transactions on Industry Applications* vol.14, n° 1, pp.:) 810-818, 1999.
- [THO99b] Thomson W. T., Rankin D., Dorrell D. G. y On-line current monitoring to diagnose air gap eccentricity in large three-phase induction motors- industrial case histories verify the predictions", *IEEE Transactionson Energy Conversion* vol.14, n° 4, pp: 1372-1378, 1999.
- [THO01] Thomson W.T., "On-Line Fault Diagnosis in Induction Motor Drives via MCSA", *EM Diagnostics Ltd, Scotland*, 2001.
- [TIM08] Timusk M., Lipsett M. y Mechefske C.K., "Fault detection using transient machine signals", *Mechanical Systems and Signal Processing* vol.22, n° 7, pp.: 1724-1749, 2008.
- [TOL13] Toliyat, H.M., Nandi, S., Choi, S. y Meshgin-Kelk, H., "Electric machines. Modelling, condition monitoring and fault diagnosis", *CRC Press, Boca Raton, EE.UU.*, 2013.
- [TOL96] Toliyat H. A., Arefeen M. S. y Parlos A. G., "A method for dynamic simulation of air-gap eccentricity in induction machines", *IEEE Transactions on Industry Applications* vol.32, n° 4, pp.: 910-918, 1996.
- [TRA09] Tran V.T., Yang B.S., Oh M.S. y Tan A.C.C., "Fault diagnosis of induction motor based on decision trees and adaptive neuro-fuzzy inference", *Expert Systems with Applications* vol.36, n° 2, pp.: 1840-1849, 2009.
- [TRU02] Trutt F.C., Sottile J. y Kohler J.L., "Condition monitoring of induction motor stator windings using electrically excited vibrations", en *proceedings de: IEEE*

Referencias

- Industry Applications Society Conference, The 37th IAS Annual Meeting, pp.: 2301-2305, 2002.
- [TRZ00] Trzynadlowski A.M. y Ritchie E., "Comparative investigation of diagnostic media for induction motors: A case of rotor cage faults", IEEE Transactions on Industrial Electronics vol.47, n° 5, pp.: 1092-1099, 2000.
- [TSO08] Tsoumas I.P., Georgoulas G., Mitronikas E.D. y Safacas A.N., "Asynchronous machine rotor fault diagnosis technique using complex wavelets", IEEE Transactions on Energy Conversion vol.:23, n° 2, pp.: 444-459, 2008.
- [VAN09] Van Tung Tran, Bo-Suk Yang, Myung-Suck Oh, Andy Chit Chiow Tan "Fault diagnosis of induction motor based on decision trees and adaptive neuro-fuzzy inference", Expert Systems with Applications, vol 36, n°2, pp.: 1840-1849, mar. 2009.
- [VER96] Verma S.P., "Noise and vibrations of electrical machines and drives, their procedure and means of reduction", en proceedings de: International Conference on Power Electronics, Drives and Energy Systems for Industrial Growth, vol. 2, pp. 1031-1037, 1996.
- [VER03] Verma S.P. y Li W., "Measurement of Vibrations and Radiated Acoustic Noise of Electrical Machines", en proceeding de: Sixth International Conference on Electrical Machines and Systems, pp.: 861-866, 2003.
- [VOG88] Vogl, T. P., Mangis, J. K., Rigler, A. K., Zink, W. T. y Alkon, D. L. "Accelerating the Convergence of Back-Propagation Method", Biological Cybernetics, vol.59, pp.: 257- 263, 1988.
- [WAH75] Wahba, G. y Wold, S., "A completely automatic French curve: fitting spline functions by cross validation". Communications in Statistics - Theory and Methods. Vol.4, pp.: 1-17, 1975.
- [WAN00] Wang C. y Gao R.X., "Sensor placement strategy for in-situ bearing defect detection", en proceedings de 17th IEEE Instrumentation and Measurement Technology Conference, IMTC, Baltimore-MD, USA, vol. 3, pp. 1463-1467, 2000.
- [WAT98] Watson J.F. y Paterson N.C., "Improved techniques for rotor fault detection in three-phase induction motors", en proceedings de IEEE Industry Applications Conference 33rd IAS Annual Meeting, pp. 271-277, 1998.
- [WEI91] Weir, M. K., "A method for self-determination of adaptive learning rates in back propagation" Neural Networks, vol.:4, pp. 371- 379, 1991.
- [WER74] Werbos P., "Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences," Tesis Doctoral, Dept. of Applied Mathematics, Harvard University, Cambridge, Mass., 1974.
- [WID07a] Widodo A., Yang B.S. y Han T., "Combination of independent component analysis and support vector machines for intelligent faults diagnosis of induction motors", Expert Systems with Applications vol.:32, n° 2, pp.: 299-312, 2007.
- [WID07b] Widodo A. y Yang B.S., "Application of nonlinear feature extraction and support vector machines for fault diagnosis of induction motors", Expert Systems with Applications vol.33, n° 1, pp.: 241-250, 2007.
- [WIE98] Wieser R. S., Schagginger M., Kral C., y Pirker F., "The integration of machine fault detection into an indirect field oriented induction machine drive control scheme the Vienna monitoring method", en : Proceedings of the IEEE Industry Applications Society Annual Meeting, pp. 278-285, 1998.
- [WIE99] Wieser R., Kral C., Pirker F., y Schagginger M., "On-line rotor cage monitoring of inverter-fed induction machines by means of an improved method," IEEE Transactions on Power Electronics, vol. 14, n°. 5, pp. 858–865, set. 1999.

Referencias

- [WOL03] Wolbank T. M., Loparo K. A., y Wohrnschimmel R., "Inverter statistics for online detection of stator asymmetries in inverter-fed induction motors," *IEEE Transactions on Industry Applications*, vol. 39, n°. 4, pp. 1102–1108, jul./ago. 2003.
- [WU06] Wu B., "High-Power converters and AC drives". Wiley-Interscience, IEEE Press, New Jersey, EE.UU., 2006.
- [YAC95] Yacamini, R. y Chang, S.C., "Noise and vibration from induction machines fed from harmonic sources," *IEEE Transactions on Energy Conversion*, vol.10, n° 2, pp.286-292, jun 1995.
- [YAC98] Yacamini R., Smith K.S. y Ran L., "Monitoring torsional vibrations of electro-mechanical systems using stator currents", *Journal of Vibration and Acoustic* vol.120 n° 1, pp.: 72-79, 1998.
- [YAM97] Yam, J. Y. F., Chow, T. W. S y Leung, C. T.:"A New method in determining the initial weights of feedforward neural networks", *Neurocomputing*, vol.16, n° 1 , pp. 23- 32, 1997.
- [YAN04] Yang B.S., Han T y An J.L. "ART-Kohonen neural network for fault diagnosis of rotating machinery", *Mechanical Systems and Signal Processing* vol.18, pp.: 645–657, 2004.
- [YAN05] Yang B.S., Han T. y Hwang W.W. "Fault diagnosis of rotating machinery based on multi-class support vector machines". *Journal of Mechanical Science and Technology* vol.19, pp.: 846–859, 2005.
- [YAN06] Yang B.S. y Kim K.J., "Application of Dempster Shafer theory in fault diagnosis of induction motors using vibration and current signals", *Mechanical Systems and Signal Processing* vol.:20, n° 2, pp.: 403-420, 2006.
- [YAN07] Yang J., Lee S. B., Yoo J., Lee S., Oh Y., y Choi C., "A stator winding insulation condition monitoring technique for inverter-fed machines," *IEEE Transactions on Power Electronics*, vol. 22, no. 5, pp. 2026–2033, set. 2007.
- [YAZ05] Yazidi A., Henao H. y Capolino G.A., "Broken Rotor Bars Fault Detection in squirrel cage induction machines", en *proceedings de IEEE International Conference on Electric Machines and Drives*, pp. 741-747, 2005.
- [YE06] Ye Z., Sadeghian A. y Wu B., "Mechanical fault diagnostics for induction motor with variable speed drives using Adaptive Neuro-fuzzy Inference System", *Electric Power Systems Research* vol. 76 n° 9-10, pp.: 742-752, 2006.
- [ZAE12] Zaeri J., "Induction motors bearing fault detection using pattern recognition techniques", *Expert System with Applications*, vol. 39, n° 1, pp.: 68-73, ene. 2012.
- [ZHA03] Zhang Z., Ren Z. y Huang W., "A. Novel Detection method of motor broken rotor bars based on wavelet ridge", *IEEE Transactions on Energy Conversion* vol.18, n° 3, pp.: 417-423, 2003.
- [ZHA07] Zhang J.W., Zhu N.H., Yang L., Yao Q., LU Q., "A Fault, Diagnosis approach for broken rotor bars based on EMD and envelope analysis", *Journal of China University of Mining and Technology* vol.:17 n°2, pp.: 205-209, 2007.

Anexo I: Banco de ensayos

En este anexo se presentan los datos relativos a todos los equipos utilizados en los ensayos realizados en el Laboratorio del Departamento de Ingeniería Eléctrica en la Escuela de Ingenierías Industriales de la Universidad de Valladolid cuyos resultados son analizados en la presente tesis.

AI.1. MOTORES COMERCIALES.

En este trabajo se han empleado dos motores comerciales de la marca Siemens que fueron oportunamente modificados para reproducir la avería objeto de estudio.

Motor 1

Sus parámetros nominales se muestran en la Tabla AI.1 (Fig. AI.1).

Tabla AI.1. Características del Motor 1

Potencia nominal	0,75 kW
Tensión nominal	3x230/400 V
Conexión del estator	Estrella
Frecuencia nominal 50 Hz	50 Hz
Corriente nominal	1,9 A
Número de pares de polos	2
Número de barras del rotor	28
Velocidad nominal	1395 rpm
Denominación	3 ~ Mot 1LA7083-4AA10
Número de serie	UD 0601/70097477-12
Eficiencia	IE1
Índice de protección	IP55
Tamaño	80M IM B3
Clase térmica	ThcL F
Factor de Servicio	1,1



Figura AI.1. Motor de 750 W de Siemens (Motor 1).

Motor 2

Sus parámetros nominales se muestran en la Tabla I.2 (Fig. AI.2).

Tabla AI.2. Características del Motor 2

Potencia nominal	1,1 kW
Tensión nominal	3x230/400 V
Conexión del estator	Estrella
Frecuencia nominal 50 Hz	50 Hz
Corriente nominal	2,6 A
Número de pares de polos	2
Número de barras del rotor	28
Velocidad nominal	1415 rpm
Denominación	3 ~ Mot 1LA7090-51
Número de serie	UD 0701/70749029-51
Eficiencia	EFF2
Índice de protección	IP55
Tamaño	90S IM B3
Clase térmica	ThL F
Factor de Servicio	1,1



(a)



(b)

Figura AI.2 Motor de 1,1 kW de Siemens (Motor 2) (a) conectado al freno y (b) desarmado.

AI.2. VARIADORES DE FRECUENCIA.

Se han empleado los siguientes variadores de frecuencia comerciales:

Variador PowerFlex 40 de Allen-Bradley (Fig. AI.3).

Tabla AI.3. Características del Variador PowerFlex 40 de Allen-Bradley

Potencia nominal	2,2 kW
Tensión y frecuencia de alimentación	3x380 - 480 V (48-63 Hz)
Tensión de salida	0 - 460 V
Corriente nominal	7,5 A
Frecuencia de salida	0 - 400 Hz
Corriente máx. de salida en continuo	6 A
Sobrecarga temporal (60 seg)	9 A
Denominación	22B-D6P0N104
Número de serie	BD6P0N0W8500204
Índice de protección	IP20



Figura AI.3. Variador de frecuencia PowerFlex 40 de Allen-Bradley.

Variador MicroMaster 420 de Siemens (Fig. AI.4).

Tabla AI.4. Características del Variador MicroMaster 420 de Siemens

Potencia nominal	4 kW
Tensión y frecuencia de alimentación	3x380 - 480 V 47-63 Hz
Tensión de salida	0 – Tensión de Entrada V
Frecuencia de salida	0 - 650 Hz
Corriente máx. de salida en continuo	10,2
Denominación	6SE6420-2UD24-0BA1
Número de serie	XAW902-006579
Índice de protección	IP20



Figura AI.4. Variador de frecuencia Micromaster 420 de Siemens.

Variador Altivar 66 de Telemecánica (Fig. AI.5).

Tabla AI.5. Características del Variador Altivar 66

Potencia nominal	2,2 kW
Tensión y frecuencia de alimentación	3x400 V – 15% a 460 V + 15% 50/60 Hz ±5%
Tensión de salida	0 – Tensión de Entrada V
Corriente nominal	9 A
Frecuencia de salida	0,1 – 400 Hz
Corriente máx. de salida en continuo	5,8 A
Sobrecarga temporal (60 seg)	8 A
Denominación	ATV-66U41N4
Índice de protección	IP20



Figura AI.5. Variador de frecuencia Altivar 66 de Telemecánica.

AI.3. FRENO Y UNIDAD DE CONTROL.

Para cargar el motor y simular un par resistente constante, se ha empleado un freno de polvo magnético de Lucas-Nülle (Fig. AI.6).

Tabla AI.6. Características del freno de polvo magnético Lucas- Nülle

Potencia nominal	1 kW
Tensión y frecuencia de alimentación	230 V 50 Hz
Par resistente	0 – 25 Nm
Velocidad de giro	0 – 6000 rpm
Denominación	SE 2662-5R

El freno de polvo magnético va acompañado de una unidad de control, también de Lucas-Nülle, que permite fijar el valor del par resistente que ejerce el freno (Fig. AI.7). Además, también incorpora unos indicadores de medida donde se muestra la velocidad de giro y el par resistente ejercido por el freno. Esta información no se ha empleado.

Tabla AI.7. Características de la unidad de control Lucas- Nülle

Tensión y frecuencia de alimentación	230 V 50 Hz
Denominación	SO 3213-7S



Figura AI.7. Freno de polvo magnético y unidad de control de Lucas-Nülle.

AI.4. SENSORES.

Para el registro de las diferentes magnitudes se han empleado los siguientes transductores o sensores. Estos sensores, con empaquetamiento PCB, se montaron sobre dos placas de diseño propio y construidas en el propio laboratorio (Fig. AI.8).




Figura AI.8. Tarjetas dedicadas con los transductores de efecto Hall de tensión y corriente.

AI.4.1. TRANSDUCTORES DE CORRIENTE.

Se han utilizado dos transductores de corriente de Honeywell y un tercero de LEM, todos basados en el efecto Hall.

Transductor de corriente de Honeywell (Fig. AI.9).

Datos técnicos:

- Denominación: CSNE151
- Corriente primaria (valor máximo en continuo): ± 36 A
- Tensión primaria (AC y DC): 10-500 V.
- Corriente secundaria nominal: 25 mA (eficaces)
- Tensión de alimentación: ± 15 Vdc.
- Consumo de corriente: 10 (@ ± 15 V)+ Corriente secundaria mA.
- Ratio de conversión: 2500:1000
- Precisión: $\pm 0,5$ %
- Tiempo de respuesta: 1 μ s
- Empaquetamiento: PCB



Figura AI.9. Transductor de corriente de Honeywell.

Transductor de corriente de LEM (Fig. AI.10).

Datos técnicos:

- Denominación: LA 25-NP
- Corriente primaria nominal: 25 mA (eficaces)
- Rango de medida: 0 .. ± 36 A
- Corriente secundaria nominal: 25 mA (eficaces)
- Tensión de alimentación: ± 15 V.
- Consumo de corriente: 10 + Corriente secundaria mA.
- Precisión: $\pm 0,5$ %
- Tiempo de respuesta: 1 μ s
- Ancho de Banda (-1 dB): DC .. 150 kHz
- Empaquetamiento: PCB




Figura AI.10. Transductor de corriente de LEM.

AI.4.2. TRANSDUCTOR DE TENSIÓN.

Para realizar la medida de tensión se empleó un transductor de Efecto Hall de LEM (Fig. AI.11). El sensor tiene un lado primario donde se conectan los terminales cuya tensión se quiere medir. La conexión no es directa, se realiza a través de una resistencia externa R_1 . De esta forma, pasa una corriente de mA por el primario del sensor. La máxima precisión se obtiene cuando esta corriente se aproxima a los 10 mA. R_1 se calcula para que, a la máxima tensión que se va a medir, la corriente que circula por el primario del sensor sea precisamente 10 mA. En ese caso, la precisión será $\pm 0,8$ % de la tensión de entrada. La salida del sensor es otra corriente, denominada secundaria, que es proporcional a la tensión de entrada y que se hace circular por otra resistencia externa R_M para efectuar la medida de tensión.

Anexo I: Banco de ensayos

Datos técnicos:

- Corriente primaria nominal: 10 mA (eficaces)
- Tensión primaria (AC y DC): 10-500 V.
- Corriente secundaria nominal: 25 mA (eficaces)
- Tensión de alimentación: $\pm 12-15$ V.
- Consumo de corriente: 10 (@ ± 15 V)+ Corriente secundaria mA.
- Ratio de conversión: 2500:1000
- Precisión a la corriente primaria nominal y 25 °C de temperatura:
- @ ± 12 V..15 V: $\pm 0,9$ %
- @ ± 15 V ($\pm 5\%$): $\pm 0,8$ %
- Tiempo de respuesta a un escalón del 90% de la corriente primaria nominal: 40 μ s
- Empaquetamiento: PCB



Figura AI.11. Transductor de tensión.

AI.5. SISTEMA DE ADQUISICIÓN (Hardware y Software).

El sistema de adquisición de datos se basó en una plataforma de National Instruments (Fig. AI.12), que consiste en un sistema modular formado por:

- Chasis compacto: NI cDAQ-9174. Este chasis permite la conexión de hasta 4 módulos de E/S.
- Módulo de adquisición: NI 9215.



Figura AI.12. Sistema de adquisición de datos de National Instruments.

Chasis NI cDAQ-9174

- Denominación: 781157-01
- Número de serie: 14E8524.
- Alimentación: 9-30 V.
- Potencia máxima consumida: 15 W.
- Número de Contadores/Temporizadores: 4
- Resolución: 32 bits
- Interfaz de Bus: USB 2.0 de Alta Velocidad
- Transferencias de Datos de Alto Rendimiento: 7
- Número de ranuras: 4

Módulo NI 9215

- Denominación: 779011-01
- Número de serie: 199269A-1L 14C7DAA
- Tipos de Medida: Voltaje
- Tipo de Aislamiento: Aislamiento de Canal a Tierra
- Compatibilidad con RoHS: Sí
- Entrada Analógica: Sí
- Canales: 4
- Canales Diferenciales: 4
- Resolución: 16 bits
- Velocidad de Muestreo: 100 kS/s
- Máx. Voltaje de Entrada Analógica: 10 V
- Rango de Voltaje Máximo: -10 V a 10 V
- Precisión Máxima del Rango de Voltaje: 0.003 V
- Muestreo Simultáneo: Sí
- Conector de E/S: Conectores BNC
- Temperatura de Operación: -40 a 70 °C

Anexo I: Banco de ensayos

El sistema de adquisición se conecta vía USB 2.0 a un PC portátil (Fig. AI.13), modelo 6717s de HP Compaq, que dispone de un procesador AMD Turion 64 con 4 GB de memoria RAM. El sistema operativo es Windows 7 Professional de 64 bits. El software que realiza la adquisición es Matlab, versión R2010. En este mismo software se realiza el cálculo del PSD, transformada de Hilbert y de los estadísticos en el dominio temporal. Los resultados de los ensayos se guardan en un archivo punto “mat” donde se almacena las señales medidas (corriente de las tres fases; una tensión fase-neutro) en función del tiempo y los espectros (PSD) correspondientes de estas tres señales.



Figura AI.13. Ordenador portátil del sistema de adquisición de datos.

AI.6 Sensor de velocidad.

El sensor de velocidad es un sensor de contraste que mide la velocidad de giro del motor mediante el contraste blanco-negro producido por una banda de esos mismos colores instalada en el eje del rotor del motor de inducción. El sensor es un S60W de la marca Datalogic.




Figura AI.14: Sensor de contraste instalado en el banco de ensayos

Tabla AI.8: Especificaciones técnicas del sensor de contraste

Características Técnicas	
Tensión de alimentación	10 – 30 Vdc
Rizado	2 Vpp max.
Consumo de corriente	30 mA
Outputs	PNP o NPN 30 Vdc.
Corriente de salida	100 mA
Voltaje de saturación de salida	$\leq 2V$
Tiempo de respuesta	100 μ s
Frecuencia de conmutación	5 kHz
Indicadores	LED's (amarillo, verde y rojo).
Ajustes	Botón de ajuste
Memoria de datos	EEPROM
Temperatura de operación	-10 – 55 °C
Distancia de funcionamiento	19 \pm 2 mm

Anexo I: Banco de ensayos

Este sensor de contraste entrega una señal entre 0 y 30 voltios dependiendo del contraste que esté leyendo. Esto se traduce en que la señal que es recibida por un tacómetro digital que muestra la velocidad en rpm en un pantalla en formato numérico. La señal indica que el rotor ha realizado una vuelta completa cuando se completan 18 ciclos de la señal debido a que es el número de ranuras que la banda blanca y negra posee a lo largo de su perímetro. En la Tabla I.8 se muestran las especificaciones técnicas del sensor de contraste.

Anexo II: Resultados del Análisis de Correlación.

Para facilitar la interpretación de los resultados se reproducen las Tablas 6.1, 6.2 y 6.3 con la descripción y nomenclatura de las características indicativas de fallo.

Tabla AII.1 Características del espectro de la corriente, obtenidas mediante la Transformada de Fourier.

<u>Banda lateral</u>	<u>Nomenclatura</u>	<u>Frecuencia</u>
1 ^{er} armónico, 1 ^{ra} banda inferior	BI	$f_{bi} = (1 - 2s)f_1$
1 ^{er} armónico, 2 ^{da} banda inferior	BI2	$f_{bi2} = (1 - 4s)f_1$
1 ^{er} armónico, 1 ^{ra} banda superior	BS	$f_{bs} = (1 + 2s)f_1$
1 ^{er} armónico, 2 ^{da} banda superior	BS2	$f_{bs2} = (1 + 4s)f_1$
5 ^{to} armónico, 1 ^{ra} banda inferior	B5I	$f_{b5i} = (5 - 2s)f_1$
5 ^{to} armónico, 1 ^{ra} banda superior	B5S	$f_{b5s} = (5 + 2s)f_1$
7 ^{mo} armónico, 1 ^{ra} banda inferior	B7I	$f_{b7i} = (7 - 2s)f_1$
7 ^{mo} armónico, 1 ^{ra} banda superior	B7S	$f_{b7s} = (7 + 2s)f_1$

Tabla AII.2 Características del espectro de la corriente, obtenidas mediante la Transformada de Hilbert.

<u>Banda lateral</u>	<u>Nomenclatura</u>	<u>Frecuencia</u>
1 ^{er} armónico, 1 ^{ra} banda superior	HS	$f_{hs} = 2sf_1$
1 ^{er} armónico, 2 ^{da} banda superior	HS2	$f_{hs2} = 4sf_1$
5 ^{to} armónico, 1 ^{ra} banda inferior	H5I	$f_{h5i} = (4 - 2s)f_1$
5 ^{to} armónico, 1 ^{ra} banda superior	H5S	$f_{h5s} = (4 + 2s)f_1$
7 ^{mo} armónico, 1 ^{ra} banda inferior	H7I	$f_{h7i} = (6 - 2s)f_1$
7 ^{mo} armónico, 1 ^{ra} banda superior	H7S	$f_{h7s} = (6 + 2s)f_1$

Anexo II: Resultados del Análisis de Correlación.

Tabla AII.3 Características estadísticas seleccionadas.

	<u>Característica estadística</u>	<u>Ecuación</u>	<u>Nomenclatura</u>
1	Momento de 1 ^{er} Orden (Promedio).	$m_1 = \frac{1}{n} \sum (x)$	1 ^{er} M
2	Momento de 2 ^{do} Orden (Varianza).	$m_2 = \frac{1}{n} \sum (x - \bar{x})^2$	2 ^{do} M
3	Momento de 3 ^{er} Orden.	$m_3 = \frac{1}{n} \sum (x - \bar{x})^3$	3 ^{er} M
4	Momento de 4 ^{to} Orden.	$m_4 = \frac{1}{n} \sum (x - \bar{x})^4$	4 ^{to} M
5	Momento de 6 ^{to} Orden Normalizado.	$m_6 = \frac{1}{(n * m_2)} \sum (x - \bar{x})^6$	6 ^{to} M
*	Cumulante de 1 ^{er} Orden.	$c_1 = m_1$	
6	Cumulante de 2 ^{do} Orden.	$c_2 = m_2 - m_1^2$	2 ^{do} C
7	Cumulante de 3 ^{er} Orden.	$c_3 = m_3 - 3m_1m_2 + 2m_1^3$	3 ^{er} C
8	Cumulante de 4 ^{to} Orden.	$c_4 = m_4 + m_3m_1 - 3m_2^2 + 12m_2m_1^2 - 6m_1^4$	4 ^{to} C
9	Skewness o asimetría.	$Skew = \frac{m_3}{(\sqrt{m_2})^3}$	Skew
10	Curtosis.	$Curt = \frac{m_4}{(\sqrt{m_2})^4}$	Curt
11	Promedio de valores absolutos.	$ \bar{x} = \frac{1}{n} \sum x $	PVA
12	Máximo valor absoluto.	$x_p = \max x $	MVA
13	Valor cuadrático medio.	$x_r = \left(\frac{1}{n} \sum \sqrt{ x } \right)^2$	VCM
**	Valor eficaz o RMS (<i>Root Mean Square</i>)	$X_{rms} = \sqrt{\frac{1}{N} \sum (x - \bar{x})^2}$	
14	Factor de Cresta.	$f_c = \frac{x_p}{x_{rms}}$	FC
15	Factor de forma.	$f_f = \frac{x_{rms}}{ \bar{x} }$	FF

* se incluye únicamente para indicar que el 1^{er} Cumulante es igual al 1^{er} momento, por lo que no representa una nueva característica y ** tampoco es una característica nueva porque representa al valor eficaz ya considerada como característica relacionada al nivel de carga del motor.

Anexo II: Resultados del Análisis de Correlación.

En la tabla AII.4 se presentan los resultados del Análisis de Correlación. En la fila se indica la nomenclatura de la característica y en columna el grupo de ensayos. En cada celda se indica con un “1” si la característica fue seleccionada por el análisis de correlación y con una celda vacía si fue eliminada por estar muy correlacionada con otra característica. La última fila indica la cantidad de características con correlación inferior al 0,9 para cada grupo de ensayos y la última columna el porcentaje de veces que fue seleccionada cada característica.

Tabla AII.4. Características estadísticas seleccionadas.

	M1	M1 50 Hz	Alt	Alt 35Hz	Alt 50Hz	Alt 65Hz	M1 Red	M2	M2 65Hz	M2 50Hz	M2 35Hz	M2 Red	AB	AB35Hz	AB50Hz	AB65Hz	SM	SM35Hz	SM50Hz	SM65Hz	Promedio	
BI	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	100,0%
BS	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	100,0%
BI2	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	100,0%
BS2			1	1	1	1		1	1	1	1	1	1	1	1	1	1	1	1	1	1	85,0%
B5I	1	1	1	1	1	1		1	1	1	1	1	1	1	1	1	1	1	1	1	1	95,0%
B5S	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	100,0%
B7I	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	100,0%
B7S			1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	90,0%
1 ^{er} M		1				1			1	1	1	1	1	1	1	1	1	1	1	1	1	70,0%
2 ^{do} M																						0,0%
3 ^{er} M						1	1		1											1	1	25,0%
4 ^{to} M																						0,0%
6 ^{to} M	1		1	1	1	1			1			1										35,0%
2 ^{do} C																						0,0%
3 ^{er} C	1	1	1	1	1	1	1		1	1			1	1	1	1	1				1	75,0%
4 ^{to} C																1						5,0%
SKEW	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1		1	1	1	1	1	95,0%
CURT	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	100,0%
PVA	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1		1	1	1	1	1	95,0%
MVA	1		1			1				1			1		1		1		1		1	40,0%
CVM																						0,0%
FC	1	1	1	1	1	1	1	1	1	1	1	1	1		1	1	1	1	1	1	1	95,0%
FF	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	100,0%
HS	1	1	1	1		1		1	1	1	1	1	1	1	1	1	1	1	1	1	1	90,0%
HS2	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	100,0%
H5I	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	100,0%
H5S	1	1	1	1	1	1	1	1		1	1	1	1	1	1		1	1	1			85,0%
H7I	1	1	1	1	1	1		1	1	1	1	1	1	1	1		1	1			1	85,0%
H7S	1	1	1	1	1	1	1	1	1	1		1	1	1	1						1	75,0%
	20	19	22	21	20	24	17	19	22	22	19	21	22	20	22	17	21	19	20	21		20,4

Anexo III: Resultados de los algoritmos estudiados

Para facilitar la interpretación de los resultados se reproducen las Tablas 8.1 y 8.2 con la descripción de los grupos de ensayos y formas de clasificación.

Tabla AIII.1 Nomenclatura de los grupos de ensayos según el tipo de alimentación.

	Nomenclatura	Descripción del grupo
1	M1	Todos los ensayos obtenidos con el Motor M1
2	M1 50 Hz	Los ensayos obtenidos con el M1 a 50 Hz, incluyendo los ensayos con alimentación de red y con variador
3	Alt	Los ensayos obtenidos con el Motor 1 y el variador Altivar a 35 Hz, 50 Hz y 65 Hz
4	Alt 35Hz	Los ensayos obtenidos con el Motor 1 y el variador Altivar a 35 Hz
5	Alt 50Hz	Los ensayos obtenidos con el Motor 1 y el variador Altivar a 50 Hz
6	Alt 65Hz	Los ensayos obtenidos con el Motor 1 y el variador Altivar a 65 Hz
7	M1 Red	Los ensayos obtenidos con el Motor 1 y alimentación de red
8	M2	Todos los ensayos obtenidos con el Motor M2
9	M2 65Hz	Los ensayos obtenidos con el M2 a 65 Hz, incluyendo los ensayos con alimentación del variador Allen Bradley y Siemens
10	M2 50Hz	Los ensayos obtenidos con el M2 a 50 Hz, incluyendo los ensayos con alimentación del variador Allen Bradley, Siemens y red
11	M2 35Hz	Los ensayos obtenidos con el M2 a 35 Hz, incluyendo los ensayos con alimentación del variador Allen Bradley y Siemens
12	AB	Los ensayos obtenidos con el Motor 2 y el variador Allen-Bradley a 35 Hz, 50 Hz y 65 Hz
13	AB 35Hz	Los ensayos obtenidos con el Motor 2 y el variador Allen Bradley a 35 Hz
14	AB 50Hz	Los ensayos obtenidos con el Motor 2 y el variador Allen Bradley a 50 Hz
15	AB 65Hz	Los ensayos obtenidos con el Motor 2 y el variador Allen Bradley a 65 Hz
16	SM	Los ensayos obtenidos con el Motor 2 y el variador Siemens a 35 Hz, 50 Hz y 65 Hz
17	SM 35Hz	Los ensayos obtenidos con el Motor 2 y el variador Siemens a 35 Hz
18	SM 50Hz	Los ensayos obtenidos con el Motor 2 y el variador Siemens a 50 Hz
19	SM 65Hz	Los ensayos obtenidos con el Motor 2 y el variador Siemens a 65 Hz
20	M2 Red	Los ensayos obtenidos con el Motor 2 y alimentación de red

Tabla AIII.2 Definición de las formas de clasificación consideradas.

Nomenclatura	Definición de la forma de clasificación
F_{123}	Discrimina entre los cuatro estados de fallo considerados: Motor Sano, Fallo Leve, Fallo Medio y Barra Rota.
F_1	Discrimina solamente entre motor sano y motor sano, es decir, separa en: i) motor Sano, ii) motor con Fallo Leve, Fallo Medio o Barra Rota.
F_2	Discrimina entre motor sano o con Fallo Leve y motor con Fallo o Medio o Barra Rota, separa en: i) Motor Sano o Fallo Leve, ii) Fallo Medio o Barra Rota.
F_3	Discrimina entre motor con Barra Rota y el resto, separa en: i) Motor Sano, Fallo Leve o Fallo Medio, ii) motor con Barra Rota.

Resultados del Análisis Discriminante

Resultados del Análisis Discriminante empleando el conjunto original de variables, “V.O.” y el conjunto reducido de variables, “V.R.” En todos los casos se presenta el porcentaje de clasificación correcta ponderada.

Motor 1

	M1	M1 50 Hz	Alt	Alt 35Hz.	Alt 50Hz.	Alt 65Hz.	M1 Red
V.O. F ₁₂₃	80,7%	82,0%	94,4%	99,4%	100,0%	100,0%	99,1%
V.R. F ₁₂₃	97,5%	99,9%	98,3%	100,0%	100,0%	100,0%	100,0%
V.O. F ₁	83,5%	84,6%	89,5%	86,5%	89,4%	99,7%	99,4%
V.R. F ₁	97,6%	99,8%	97,4%	100,0%	100,0%	99,5%	99,8%
V.O. F ₂	99,4%	99,0%	99,1%	100,0%	99,9%	100,0%	99,0%
V.R. F ₂	99,4%	100,0%	99,4%	100,0%	100,0%	100,0%	100,0%
V.O. F ₃	92,8%	95,0%	92,4%	95,2%	100,0%	95,8%	91,8%
V.R. F ₃	99,6%	99,5%	100,0%	100,0%	100,0%	100,0%	99,6%

Motor 2

	M2	M2 65Hz	M2 50Hz	M2 35Hz	M2 Red	AB	AB35Hz
V.O. F ₁₂₃	59,4%	69,3%	63,9%	75,5%	69,5%	65,6%	89,6%
V.R. F ₁₂₃	69,0%	85,6%	76,0%	83,7%	84,6%	90,5%	92,2%
V.O. F ₁	72,1%	78,7%	71,6%	88,2%	74,2%	76,4%	89,5%
V.R. F ₁	81,9%	85,5%	85,4%	94,0%	90,1%	88,6%	93,7%
V.O. F ₂	88,5%	93,2%	86,7%	94,4%	85,9%	94,1%	92,5%
V.R. F ₂	93,1%	94,5%	90,8%	95,6%	91,7%	96,2%	95,7%
V.O. F ₃	81,0%	83,8%	82,2%	85,6%	83,1%	86,8%	91,9%
V.R. F ₃	85,2%	94,3%	82,3%	87,0%	85,5%	94,6%	97,0%

	AB50Hz	AB65Hz	SM	SM35Hz	SM50Hz	SM65Hz
V.O. F ₁₂₃	80,5%	86,9%	71,1%	90,2%	78,6%	85,4%
V.R. F ₁₂₃	90,6%	96,1%	73,6%	95,3%	84,9%	93,0%
V.O. F ₁	75,6%	77,8%	83,2%	90,1%	88,7%	94,4%
V.R. F ₁	90,8%	93,3%	83,1%	99,4%	95,2%	99,9%
V.O. F ₂	94,3%	96,4%	93,1%	95,6%	92,3%	91,1%
V.R. F ₂	97,3%	96,6%	92,6%	97,1%	90,8%	95,4%
V.O. F ₃	89,1%	87,0%	83,1%	86,3%	75,4%	91,1%
V.R. F ₃	91,7%	99,4%	82,2%	96,4%	79,5%	96,5%

Resultados de la Regresión Logística

Resultados de la Regresión Logística empleando el conjunto original de variables, “V.O.” y el conjunto reducido de variables, “V.R.” En todos los casos se presenta el porcentaje de clasificación correcta ponderada.

Motor 1

	M1	M1 50 Hz	Alt	Alt 35Hz.	Alt 50Hz.	Alt 65Hz.	M1 Red
V.O. F ₁₂₃	98,6%	99,4%	98,0%	99,8%	100,0%	99,8%	99,0%
V.R. F ₁₂₃	98,4%	99,3%	99,3%	100,0%	100,0%	100,0%	98,7%
V.O. F ₁	99,4%	99,7%	99,6%	99,9%	100,0%	100,0%	99,5%
V.R. F ₁	98,2%	99,7%	99,1%	100,0%	100,0%	100,0%	99,5%
V.O. F ₂	100,0%	99,2%	100,0%	100,0%	100,0%	100,0%	98,5%
V.R. F ₂	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%	99,9%
V.O. F ₃	100,0%	99,0%	100,0%	100,0%	100,0%	100,0%	99,2%
V.R. F ₃	100,0%	99,7%	100,0%	100,0%	100,0%	100,0%	98,9%

Motor 2

	M2	M2 65Hz	M2 50Hz	M2 35Hz	M2 Red	AB	AB35Hz
V.O. F ₁₂₃	77,8%	89,5%	81,3%	94,7%	86,9%	92,0%	95,4%
V.R. F ₁₂₃	78,0%	91,4%	79,0%	85,1%	86,4%	93,3%	95,8%
V.O. F ₁	85,2%	93,6%	89,4%	97,7%	88,0%	92,0%	95,6%
V.R. F ₁	83,5%	85,8%	87,5%	95,8%	90,2%	91,8%	95,4%
V.O. F ₂	93,3%	93,7%	91,2%	95,5%	87,9%	95,9%	94,9%
V.R. F ₂	93,7%	94,8%	91,3%	96,5%	91,8%	96,2%	97,8%
V.O. F ₃	85,1%	92,7%	86,8%	96,8%	83,2%	92,8%	99,5%
V.R. F ₃	84,7%	94,8%	86,9%	86,1%	90,4%	94,5%	98,5%

	AB50Hz	AB65Hz	SM	SM35Hz	SM50Hz	SM65Hz
V.O. F ₁₂₃	88,4%	96,4%	85,5%	98,1%	88,4%	93,5%
V.R. F ₁₂₃	93,6%	96,9%	86,4%	98,5%	92,5%	95,2%
V.O. F ₁	90,0%	95,4%	93,2%	98,7%	93,8%	99,7%
V.R. F ₁	93,1%	94,5%	89,7%	98,3%	95,1%	99,5%
V.O. F ₂	96,2%	97,3%	92,8%	96,3%	87,8%	93,5%
V.R. F ₂	96,5%	98,2%	94,0%	95,2%	91,3%	95,0%
V.O. F ₃	91,6%	99,5%	90,4%	98,0%	85,1%	99,7%
V.R. F ₃	96,0%	99,6%	90,9%	95,9%	77,1%	96,5%

Resultados de las Redes Neuronales

Resultados de las Redes Neuronales simples, empleando el conjunto original de variables, “V.O.” y el conjunto reducido de variables, “V.R.” En todos los casos se presenta el porcentaje de clasificación correcta ponderada.

Motor 1

	M1	M1 50 Hz	Alt	Alt 35Hz.	Alt 50Hz.	Alt 65Hz.	M1 Red
V.O. F ₁₂₃	98,8%	99,2%	98,4%	99,1%	99,7%	99,2%	98,8%
V.R. F ₁₂₃	99,2%	99,4%	99,2%	99,7%	100,0%	99,9%	98,7%
V.O. F ₁	99,6%	99,6%	99,6%	100,0%	99,9%	99,9%	99,4%
V.R. F ₁	99,6%	99,9%	99,5%	99,9%	100,0%	100,0%	99,5%
V.O. F ₂	99,7%	99,5%	99,9%	100,0%	100,0%	99,9%	99,0%
V.R. F ₂	99,8%	99,7%	99,8%	100,0%	99,9%	100,0%	99,2%
V.O. F ₃	99,6%	99,4%	99,9%	100,0%	100,0%	99,7%	99,0%
V.R. F ₃	99,6%	99,7%	99,9%	100,0%	100,0%	99,9%	99,2%

Motor 2

	M2	M2 65Hz	M2 50Hz	M2 35Hz	M2 Red	AB	AB35Hz
V.O. F ₁₂₃	90,6%	93,5%	88,9%	95,3%	87,2%	92,2%	94,2%
V.R. F ₁₂₃	89,8%	94,3%	89,6%	94,2%	90,5%	93,1%	95,7%
V.O. F ₁	94,9%	97,1%	92,7%	96,8%	91,2%	94,6%	96,2%
V.R. F ₁	92,9%	96,3%	91,8%	97,7%	93,1%	94,6%	96,4%
V.O. F ₂	95,6%	95,9%	94,3%	95,8%	92,1%	96,1%	95,4%
V.R. F ₂	94,6%	96,5%	94,1%	96,7%	93,3%	96,8%	96,8%
V.O. F ₃	95,0%	96,8%	92,9%	96,9%	87,6%	95,4%	97,4%
V.R. F ₃	93,0%	98,4%	91,0%	96,7%	91,1%	96,2%	97,6%

	AB50Hz	AB65Hz	SM	SM35Hz	SM50Hz	SM65Hz
V.O. F ₁₂₃	87,8%	94,7%	93,1%	96,3%	90,5%	94,0%
V.R. F ₁₂₃	90,7%	96,3%	95,2%	96,9%	94,4%	96,6%
V.O. F ₁	90,3%	95,3%	96,4%	98,6%	93,6%	99,2%
V.R. F ₁	94,0%	95,7%	97,7%	98,7%	95,2%	99,6%
V.O. F ₂	95,8%	97,2%	94,3%	97,2%	91,5%	95,1%
V.R. F ₂	96,6%	98,5%	95,4%	97,5%	94,3%	96,3%
V.O. F ₃	92,9%	98,1%	95,5%	98,4%	91,4%	97,5%
V.R. F ₃	95,3%	99,0%	95,3%	98,5%	93,6%	97,5%

Resultados del Ensamble de 3 ANN

Resultados del Ensamble de 3 ANN, empleando el conjunto original de variables, “V.O.” y el conjunto reducido de variables, “V.R.” En todos los casos se presenta el porcentaje de clasificación correcta ponderada.

Motor 1

	M1	M1 50 Hz	Alt	Alt 35Hz.	Alt 50Hz.	Alt 65Hz.	M1 Red
V.O. F ₁₂₃	99,6%	99,5%	99,6%	100,0%	100,0%	99,8%	99,2%
V.R. F ₁₂₃	99,9%	99,7%	99,9%	100,0%	100,0%	100,0%	99,4%
V.O. F ₁	99,9%	99,7%	99,9%	100,0%	100,0%	100,0%	99,5%
V.R. F ₁	100,0%	99,9%	99,8%	100,0%	100,0%	100,0%	99,5%
V.O. F ₂	99,9%	99,5%	99,9%	100,0%	100,0%	99,8%	99,4%
V.R. F ₂	100,0%	99,9%	100,0%	100,0%	100,0%	100,0%	99,4%
V.O. F ₃	99,6%	99,8%	99,9%	100,0%	100,0%	99,8%	99,3%
V.R. F ₃	99,5%	99,8%	100,0%	100,0%	100,0%	100,0%	99,5%

Motor 2

	M2	M2 65Hz	M2 50Hz	M2 35Hz	M2 Red	AB	AB35Hz
V.O. F ₁₂₃	93,0%	95,9%	92,1%	97,3%	91,2%	93,8%	96,1%
V.R. F ₁₂₃	91,7%	95,7%	91,7%	95,6%	93,2%	94,3%	96,4%
V.O. F ₁	95,9%	98,6%	94,0%	98,0%	94,4%	95,9%	97,4%
V.R. F ₁	93,9%	97,3%	92,9%	98,7%	95,1%	95,7%	96,7%
V.O. F ₂	96,5%	97,3%	95,5%	96,8%	94,4%	96,8%	96,2%
V.R. F ₂	94,9%	97,0%	95,2%	97,3%	95,1%	97,4%	97,8%
V.O. F ₃	96,6%	98,9%	95,1%	98,2%	92,3%	96,7%	98,4%
V.R. F ₃	94,4%	99,1%	92,7%	97,5%	93,7%	97,1%	97,7%

	AB50Hz	AB65Hz	SM	SM35Hz	SM50Hz	SM65Hz
V.O. F ₁₂₃	90,3%	96,5%	94,7%	98,6%	94,3%	96,5%
V.R. F ₁₂₃	92,4%	97,3%	96,1%	98,3%	95,3%	97,3%
V.O. F ₁	92,5%	96,5%	97,6%	99,4%	96,0%	99,5%
V.R. F ₁	95,6%	96,4%	98,5%	99,4%	96,2%	99,7%
V.O. F ₂	96,8%	97,8%	95,2%	98,1%	92,9%	96,2%
V.R. F ₂	96,8%	99,0%	95,8%	98,9%	95,3%	97,1%
V.O. F ₃	95,0%	99,2%	97,0%	99,4%	95,6%	98,9%
V.R. F ₃	96,5%	99,6%	96,8%	99,4%	95,3%	98,1%

Resultados del Ensamble de 10 ANN

Resultados del Ensamble de 10 ANN, empleando el conjunto original de variables, “V.O.” y el conjunto reducido de variables, “V.R.” En todos los casos se presenta el porcentaje de clasificación correcta ponderada.

Motor 1

	M1	M1 50 Hz	Alt	Alt 35Hz.	Alt 50Hz.	Alt 65Hz.	M1 Red
V.O. F ₁₂₃	99,8%	99,5%	99,9%	100,0%	100,0%	100,0%	99,3%
V.R. F ₁₂₃	100,0%	99,8%	100,0%	100,0%	100,0%	100,0%	99,2%
V.O. F ₁	100,0%	99,7%	100,0%	100,0%	100,0%	100,0%	99,5%
V.R. F ₁	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%	99,5%
V.O. F ₂	99,9%	99,8%	100,0%	100,0%	100,0%	100,0%	99,3%
V.R. F ₂	99,9%	99,9%	100,0%	100,0%	100,0%	100,0%	99,5%
V.O. F ₃	99,6%	99,7%	100,0%	100,0%	100,0%	100,0%	99,3%
V.R. F ₃	99,5%	99,7%	100,0%	100,0%	100,0%	100,0%	99,6%

Motor 2

	M2	M2 65Hz	M2 50Hz	M2 35Hz	M2 Red	AB	AB35Hz
V.O. F ₁₂₃	93,6%	96,1%	92,7%	97,4%	91,2%	94,1%	96,6%
V.R. F ₁₂₃	92,1%	96,0%	92,5%	96,1%	94,4%	94,9%	96,8%
V.O. F ₁	96,1%	99,0%	94,5%	98,4%	95,0%	96,5%	98,0%
V.R. F ₁	94,1%	97,5%	93,1%	98,6%	95,9%	96,0%	97,1%
V.O. F ₂	96,6%	97,3%	95,6%	97,1%	94,6%	97,3%	96,4%
V.R. F ₂	95,1%	97,5%	95,5%	97,7%	95,9%	97,5%	97,6%
V.O. F ₃	97,0%	99,4%	96,1%	98,5%	92,6%	97,1%	98,4%
V.R. F ₃	94,5%	99,5%	93,1%	98,2%	94,5%	97,5%	97,6%

	AB50Hz	AB65Hz	SM	SM35Hz	SM50Hz	SM65Hz
V.O. F ₁₂₃	91,6%	96,7%	95,4%	99,0%	95,1%	96,3%
V.R. F ₁₂₃	92,9%	97,6%	96,1%	98,6%	95,6%	97,7%
V.O. F ₁	93,3%	97,0%	97,9%	99,6%	96,3%	99,6%
V.R. F ₁	95,9%	97,0%	98,6%	99,7%	96,0%	100,0%
V.O. F ₂	97,4%	98,2%	95,6%	98,8%	93,4%	96,3%
V.R. F ₂	97,4%	99,3%	96,0%	98,9%	95,4%	97,2%
V.O. F ₃	97,1%	99,8%	97,2%	99,9%	96,0%	99,4%
V.R. F ₃	96,7%	99,9%	97,1%	99,7%	95,9%	98,5%