



Universidad de Valladolid



**ESCUELA DE INGENIERÍAS
INDUSTRIALES**

UNIVERSIDAD DE VALLADOLID

ESCUELA DE INGENIERIAS INDUSTRIALES

Grado en Ingeniería Eléctrica

**DETECCIÓN TEMPRANA DE LA
DEGRADACIÓN DE RODAMIENTOS
MEDIANTE LA MONITORIZACIÓN DE LA
CORRIENTE DE ALIMENTACIÓN DEL
MOTOR.**

Autor:

Villanueva Llorente, Iván

Tutor(es):

**Óscar Duque Pérez
Departamento de Ingeniería
Eléctrica**

Valladolid, junio 2022.

AGRADECIMIENTOS

Aprovecho esta oportunidad para agradecer:

A mis padres, mi hermano y toda mi familia. Por su apoyo incondicional en todo momento. Sin ellos no hubiera llegado hasta aquí.

A mi tutor Óscar, quien, aun teniendo una alta carga de trabajo, me ofreció la posibilidad de realizar el presente trabajo.

A mis amigos, mis compañeros de clase y profesores, por haber compartido conmigo todos estos momentos, buenos y no tan buenos, aprendiendo de todos ellos.

A todos ellos, gracias.

RESUMEN

En la actualidad los motores de inducción se encuentran a la cabeza del tipo de motor más común en la industria, constituyendo en torno al 90% de los motores presentes en la misma. Esto se debe a su robustez, precisión, fiabilidad y facilidad de regulación.

La importancia de este tipo de máquinas ocasiona que una buena planificación de su mantenimiento sea crucial. Para ello se cuenta con el mantenimiento predictivo, pudiendo anticiparse a la aparición de fallos en los motores y minimizar así el gasto provocado por posibles averías.

El objetivo de este Trabajo Fin de Grado es evaluar el comportamiento de técnicas de Machine Learning asociadas al mantenimiento predictivo frente al diagnóstico del estado de los rodamientos de motores de inducción.

Palabras clave:

Motor de inducción, rodamientos, mantenimiento predictivo, datos del motor y técnicas de Machine Learning supervisadas y no supervisadas.

ÍNDICE

AGRADECIMIENTOS	i
RESUMEN	iii
ÍNDICE	iv
ÍNDICE DE TABLAS	viii
ÍNDICE DE FIGURAS	ix
CAPÍTULO 1.INTRODUCCIÓN	1
CAPÍTULO 2.OBJETIVOS	3
CAPÍTULO 3.MOTORES DE INDUCCIÓN	5
3.1. DESCRIPCIÓN E IMPORTANCIA.....	5
3.2. PRINCIPIO DE FUNCIONAMIENTO.....	5
3.3 CIRCUITO EQUIVALENTE.....	8
3.4. COMPONENTES PRINCIPALES.....	9
3.4.1 ESTATOR.....	9
3.4.2. ROTOR.....	9
3.4.3. CARCASA.....	10
3.4.4. DEVANADOS.....	10
3.4.5. PLACA DE BORNES.....	11
3.4.6. ENTREHIERRO.....	11
3.4.7. EJE.....	11
3.4.8. RODAMIENTOS.....	11
3.5 TIPOS DE MOTORES DE INDUCCIÓN.....	15
3.5.1. MOTOR DE INDUCCIÓN DE JAULA DE ARDILLA.....	16
3.5.2. MOTOR DE INDUCCIÓN DE ROTOR CILÍNDRICO.....	16
3.5.3. MOTOR DE INDUCCIÓN DE DOBLE JAULA DE ARDILLA.....	17
3.5.4. MOTOR DE INDUCCIÓN MONOFÁSICO.....	18
CAPÍTULO 4.FALLOS MÁS COMUNES EN LOS MOTORES DE INDUCCIÓN	19
4.1. ESFUERZOS EJERCIDOS SOBRE EL MOTOR.....	19
4.2. FALLOS EN EL ESTÁTOR.....	20
4.2.1. FALLOS EN EL NÚCLEO DEL ESTÁTOR.....	21
4.2.2. FALLOS EN EL AISLAMIENTO DEL BOBINADO DEL ESTÁTOR.....	21
4.3. FALLOS EN EL ROTOR.....	27
4.4. AVERÍAS EN EL EJE.....	29

4.5. FALLOS EN LOS RODAMIENTOS.....	30
4.5.1. PERIODO DE VIDA ÚTIL DE UN RODAMIENTO.....	30
4.5.2. ESFUERZOS QUE AFECTAN A LOS RODAMIENTOS.....	32
4.6. EXCENRICIDAD.....	35
4.6.1. EXCENRICIDAD ESTÁTICA.....	36
4.6.2 EXCENRICIDAD DINÁMICA.....	36
4.6.3. EXCENRICIDAD MIXTA.....	37
4.7. CONSECUENCIAS Y COMPARACIÓN ENTRE FALLOS.....	38
CAPÍTULO 5.MANTENIMIENTO EN MOTORES DE INDUCCIÓN.....	41
5.1. TIPOS DE MANTENIMIENTO.....	41
5.1.1 MANTENIMIENTO CORRECTIVO.....	41
5.1.2. MANTENIMIENTO PREVENTIVO.....	42
5.1.3. MANTENIMIENTO PREDICTIVO.....	43
5.2. TÉCNICAS DE MANTENIMIENTO PREDICTIVO EN MOTORES DE INDUCCIÓN.....	46
5.2.1 TÉCNICA DE DIAGNÓSTICO DE LA RESISTENCIA DE AISLAMIENTO.....	46
5.2.2. ENSAYO DE ONDA DE CHOQUE.....	50
5.2.3. MÉTODOS DE ANÁLISIS DEL NÚCLEO MAGNÉTICO.....	52
5.2.4. ESTUDIO DEL CIRCUITO DEL MOTOR.....	53
5.2.5. TERMOGRAFÍA.....	53
5.2.6. ANÁLISIS DE VIBRACIONES.....	54
5.2.7. ESTUDIO DEL FLUJO AXIAL DE DISPERSIÓN.....	59
5.2.8. ANÁLISIS ESPECTRAL DE LA CORRIENTE.....	60
5.2.9. ANÁLISIS MULTIPARÁMETRO.....	65
5.2.10. MCSA PARA UN MOTOR ALIMENTADO MEDIANTE CONVERTIDOR DE FRECUENCIA.....	66
CAPÍTULO 6.MACHINE LEARNING.....	69
6.1 INTRODUCCIÓN.....	69
6.2 APRENDIZAJE SUPERVISADO.....	69
6.2.1. TÉCNICAS DE CLASIFICACIÓN.....	70
6.2.2. TÉCNICAS DE REGRESIÓN.....	72
6.3 APRENDIZAJE NO SUPERVISADO.....	74
6.3.1. HARD CLUSTERING:.....	75
6.3.2. SOFT CLUSTERING:.....	77
CAPÍTULO 7.OBTENCIÓN Y TRATAMIENTOS DE DATOS.....	79
CAPÍTULO 8.EXPOSICIÓN Y ANÁLISIS DE RESULTADOS.....	89

8.1. ANÁLISIS DEL COMPORTAMIENTO DE LAS TÉCNICAS NO SUPERVISADAS. ALGORITMO K-MEANS.	89
8.1.1 COMPORTAMIENTO DEL ALGORITMO FRENTE A RODAMIENTOS SANOS Y PRESENCIA DE FALLOS.....	90
8.1.2 COMPORTAMIENTO DEL ALGORITMO FRENTE A TRES ESTADOS DE LOS RODAMIENTOS.	100
8.1.3 COMPORTAMIENTO DEL ALGORITMO FRENTE A CINCO ESTADOS DE LOS RODAMIENTOS.	110
8.2. ANÁLISIS DEL COMPORTAMIENTO DE LAS TÉCNICAS NO SUPERVISADAS. ALGORITMO K-MEDOIDS.	121
8.3. ANÁLISIS DEL COMPORTAMIENTO DE LAS TÉCNICAS NO SUPERVISADAS. HIERARCHICAL CLUSTERING.....	124
8.4 COMPORTAMIENTO DE LAS TÉCNICAS NO SUPERVISADAS FRENTE A LA ALIMENTACIÓN DE RED CONSIDERANDO AMBOS NIVELES DE CARGA.	127
8.5 COMPORTAMIENTO DE LAS TÉCNICAS NO SUPERVISADAS FRENTE A LA ALIMENTACIÓN A 50 HZ Y NIVEL DE CARGA NOMINAL.	130
8.6. ANÁLISIS DEL COMPORTAMIENTO DE LAS TÉCNICAS SUPERVISADAS.	131
8.6.1. COMPORTAMIENTO DEL ALGORITMO SUPERVISADO FRENTE A CINCO ESTADOS DE LOS RODAMIENTOS.....	132
8.6.2. COMPORTAMIENTO DEL ALGORITMO FRENTE A DOS ESTADOS DE LOS RODAMIENTOS.	141
CAPÍTULO 9.CONCLUSIONES.	145
CAPÍTULO 10.BIBLIOGRAFÍA.	149
ANEXO 1.INSTRUMENTOS PARA LA REALIZACIÓN DE LOS ENSAYOS Y LA TOMA DE DATOS.	153
A1.1. MOTOR DE INDUCCIÓN.....	153
A1.2. VARIADORES DE FRECUENCIA	154
A.1.3. FRENO DE POLVO MAGNÉTICO Y UNIDAD DE CONTROL.....	156
A1.4. TRANSDUCTORES DE CORRIENTE.	157
A1.5. SISTEMA DE ADQUISICIÓN DE DATOS.	158
ANEXO 2.SCRIPTS EMPLEADOS.....	161
A2.1. SCRIPT_TRATAMIENTO_DATOS.....	161
A2.2. SCRIPT_TRATAMIENTO_DATOS_TRESESTADOS.	163
A2.3. SCRIPT_TRATAMIENTO_DATOS_SANO_FALLOS.....	164
A2.4. SCRIPT_CONCORDANCIA.....	166
A2.5. SCRIPT_CONCORDANCIA_TRESESTADOS.	168
A2.6. SCRIPT_CONCORDANCIA_SANO_FALLOS.....	170

A2.7. SCRIPT_CONCORDANCIA_KMEDOIDS.....	172
A2.8. SCRIPT_CONCORDANCIA_HIERARCHICAL_CLUSTERING.....	174
A2.9. SCRIPT_TRATAMIENTO_DATOS_NC2yNC1.....	176
A2.10. SCRIPT_TRATAMIENTO_DATOS_50HzNC2.....	179
A2.11. SCRIPT_CONCORDANCIA_NC2yNC1.....	183

ÍNDICE DE TABLAS.

CAPÍTULO 4.

Tabla 4.1. Factores que afectan al motor y sus consecuencias.	20
Tabla 4.2. Clases de aislamientos.	21

CAPÍTULO 5.

Tabla 5.1. Tensión de ensayo en función de la tensión nominal del motor.	47
Tabla 5.2. Estado del aislamiento en función del valor del IP.	50
Tabla 5.3. Tabla de diagnóstico del motor en función de la diferencia de amplitudes entre la fundamental y la BLI.	62

CAPÍTULO 7.

Tabla 7.1. Número de ensayos en función del tipo de fallo, nivel de carga y tipo de alimentación del motor.	84
--	----

CAPÍTULO 8.

Tabla 8.1. Precisión, exhaustividad y $F1$ de K-Means para ensayos clasificados en dos estados.	97
Tabla 8.2. Precisión, exhaustividad y $F1$ de K-Means para ensayos clasificados en tres estados.	107
Tabla 8.3. Precisión, exhaustividad y $F1$ de K-Means para ensayos clasificados en cinco estados.	116
Tabla 8.4. Precisión, exhaustividad y $F1$ de K-Medoids para ensayos clasificados en dos, tres y cinco estados.	119
Tabla 8.5. Precisión, exhaustividad y $F1$ de K-Medoids para ensayos clasificados en cinco estados.	122
Tabla 8.6. Precisión, exhaustividad y $F1$ de Hierarchical Clustering para ensayos clasificados en cinco estados.	125

Tabla 8.7. Precisión, exhaustividad y F1 de K-Means sin distinción del nivel de carga.	128
Tabla 8.8. Precisión, exhaustividad y F1 de Hierarchical Clustering sin distinción del nivel de carga.	129
Tabla 8.9. Precisiones de técnicas supervisadas para ensayos clasificados en cinco estados.	138
Tabla 8.10. Precisiones de técnicas supervisadas para ensayos clasificados en dos y cinco estados.	141

ANEXO 1.

Tabla A1.1. Parámetros nominales del motor empleado.....	153
Tabla A1.2. Parámetros nominales del variador de frecuencia WEG CFW-11	154
Tabla A1.3. Parámetros nominales del variador de frecuencia Allen-Bradley PowerFlex 40	155
Tabla A1.4. Características del freno de polvo magnético de Lucas-Nülle....	156
Tabla A1.5. Características de la unidad de control de Lucas-Nülle.	156

ÍNDICE DE FIGURAS.

CAPÍTULO 3.

Figura 3.1. Circuito equivalente exacto de un motor de inducción en régimen estacionario senoidal.....	8
Figura 3.2. Estátor de un motor jaula de ardilla	9
Figura 3.3. Estátor de un motor de rotor cilíndrico.....	9
Figura 3.4. Carcasa de un motor de inducción trifásico	10
Figura 3.5. Devanados concéntricos	10
Figura 3.6. Devanados excéntricos	10
Figura 3.7. Placa de bornes	11

Figura 3.8. Rodamientos y eje en motor jaula de ardilla	12
Figura 3.9. Rodamiento rígido de bolas	12
Figura 3.10. Rodamiento de rodillos cilíndricos	13
Figura 3.11. Rodamientos INSOCOAT.	13
Figura 3.12. Rodamientos híbridos.	14
Figura 3.13. Rodamientos de bolas de contacto angular.....	14
Figura 3.14. Rodamiento de rodillos a rótulas.	15
Figura 3.15. Rodamiento axial de rodillos a rótulas.....	15
Figura 3.16. Rotor de motor jaula de ardilla.....	16
Figura 3.17. Rotor de motor de rotor cilíndrico.	17
Figura 3.18. Rotor de motor doble jaula de ardilla.	17
Figura 3.19. Motor de inducción monofásico.	18

CAPÍTULO 4.

Figura 4.1. Motor dañado por sobrecargas térmicas.....	23
Figura 4.2. Aislamiento perforado por Efecto Corona.	24
Figura 4.3. Efecto de un cortocircuito entre fases del estátor.	26
Figura 4.4. Bobinado del estátor quemado por rotor bloqueado.....	26
Figura 4.5. Bobinado del estátor quemado por sobrecargas térmicas.	26
Figura 4.6. Bobinado del estátor quemado por falta en una fase	27
Figura 4.7. Bobinado dañando por picos de tensión	27
Figura 4.8. Fallo por fatiga en la unión de las barras y el anillo de cortocircuito	28
Figura 4.9. Desplazamiento del rotor del eje por un mal montaje.....	29
Figura 4.10. Ruptura del eje por fatiga torsional.....	30
Figura 4.11. Corrosión en la pista exterior del rodamiento por vibraciones ...	32

Figura 4.12. Descascarillado de la pista exterior del rodamiento debido a una incorrecta lubricación	34
Figura 4.13. Aparición de grietas debido al aumento de la temperatura por mala lubricación	34
Figura 4.14. Destrucción del rodamiento debido a una incorrecta lubricación	34
Figura 4.15. Estrías en la superficie del rodamiento por el paso de la corriente eléctrica	35
Figura 4.16. Cráteres en la superficie del rodamiento debido al paso de la corriente eléctrica	35
Figura 4.17. Tipos de excentricidad estática	36
Figura 4.18. Tipos de excentricidad dinámica	37
Figura 4.19. Excentricidad mixta	37
Figura 4.20. Deterioro de las chapas del estátor por excentricidad	38
Figura 4.21. Porcentaje de fallos en un motor de inducción.....	39

CAPÍTULO 5.

Figura 5.1. Ensayo de resistencia de aislamiento a un motor de tracción.....	49
Figura 5.2. Patrones de ondas resultantes del ensayo de ondas de choque .	51
Figura 5.3. Realización del ensayo “CID” al estátor de un motor	53
Figura 5.4. Punto caliente en el estátor de un motor detectado mediante termografía	54
Figura 5.5. Espectro de vibración de un motor sano y uno con una barra rota	56
Figura 5.6. Valores para el cálculo de frecuencias de fallo en rodamientos...	58
Figura 5.7. Espectro de vibración de un rodamiento para diferentes fallos ...	58
Figura 5.8. Bobina para la medida del flujo axial de dispersión	59
Figura 5.9. Diferencia de amplitud entre la componente fundamental de la corriente del estátor y la banda lateral inferior (BLI).....	62

Figura 5.10. Espectro de corriente del estátor de un motor con asimetría del rotor.....	63
---	----

CAPÍTULO 6

Figura 6.1. Representación del algoritmo Regresión Logística	70
Figura 6.2. Representación del algoritmo K-NN	71
Figura 6.3. Representación del algoritmo SVM	71
Figura 6.4. Representación del algoritmo Redes Neuronales.....	72
Figura 6.5. Representación del algoritmo Árbol de decisión	72
Figura 6.6. Representación del algoritmo Regresión Lineal.....	73
Figura 6.7. Representación del algoritmo Regresión No Lineal	73
Figura 6.8. Representación del algoritmo SVM Regression	74
Figura 6.9. Representación del algoritmo Regression Tree.....	74
Figura 6.10. Representación del algoritmo K-Means.....	75
Figura 6.11. Representación del algoritmo K-Medoids.....	75
Figura 6.12. Representación del algoritmo Hierarchical Clustering	76
Figura 6.13. Representación del algoritmo Self-Organizing Map.....	76
Figura 6.14. Representación del algoritmo Fuzzy c-Means.....	77
Figura 6.15. Representación del algoritmo Gaussian Mixture Model.....	77

CAPÍTULO 7

Figura 7.1. Rodamiento destrozado tras ser contaminado con SiC. [20].....	81
---	----

CAPÍTULO 8

Figura 8.1. Matriz de confusión y parámetros asociados de los datos RED_NC2 para dos estados.....	90
---	----

Figura 8.2. Matriz de confusión y parámetros asociados de los datos RED_NC1 para dos estados.	91
Figura 8.3. Matriz de confusión y parámetros asociados de los datos WEG_NC2 para dos estados	92
Figura 8.4. Matriz de confusión y parámetros asociados de los datos WEG_NC1 para dos estados	93
Figura 8.5. Matriz de confusión y parámetros asociados de los datos AB1_NC2 para dos estados	93
Figura 8.6. Matriz de confusión y parámetros asociados de los datos AB1_NC1 para dos estados.	94
Figura 8.7. Matriz de confusión y parámetros asociados de los datos AB2_NC2 para dos estados.	94
Figura 8.8. Matriz de confusión y parámetros asociados de los datos AB2_NC1 para dos estados.	95
Figura 8.9. Matriz de confusión y parámetros asociados de los datos AB3_NC2 para dos estados.....	95
Figura 8.10. Matriz de confusión y parámetros asociados de los datos AB3_NC1 para dos estados	96
Figura 8.11. Matriz de confusión y parámetros asociados de los datos AB4_NC2 para dos estados.	96
Figura 8.12. Matriz de confusión y parámetros asociados de los datos AB4_NC1 para dos estados.	97
Figura 8.13. Matriz de confusión y parámetros asociados de los datos RED_NC2 para tres estados.	101
Figura 8.14. Matriz de confusión y parámetros asociados de los datos RED_NC1 para tres estados.	102
Figura 8.15. Matriz de confusión y parámetros asociados de los datos WEG_NC2 para tres estados	102
Figura 8.16. Matriz de confusión y parámetros asociados de los datos WEG_NC1 para tres estados.....	103
Figura 8.17. Matriz de confusión y parámetros asociados de los datos AB1_NC2 para tres estados.....	103

Figura 8.18. Matriz de confusión y parámetros asociados de los datos AB1_NC1 para tres estados.....	104
Figura 8.19. Matriz de confusión y parámetros asociados de los datos AB2_NC2 para tres estados.	104
Figura 8.20. Matriz de confusión y parámetros asociados de los datos AB2_NC1 para tres estados.	105
Figura 8.21. Matriz de confusión y parámetros asociados de los datos AB3_NC2 para tres estados.....	105
Figura 8.22. Matriz de confusión y parámetros asociados de los datos AB3_NC1 para tres estados.	106
Figura 8.23. Matriz de confusión y parámetros asociados de los datos AB4_NC2 para tres estados.....	106
Figura 8.24. Matriz de confusión y parámetros asociados de los datos AB4_NC1 para tres estados.....	107
Figura 8.25. Matriz de confusión y parámetros asociados de los datos RED_NC2 para cinco estados.	110
Figura 8.26. Matriz de confusión y parámetros asociados de los datos RED_NC1 para cinco estados.....	111
Figura 8.27. Matriz de confusión y parámetros asociados de los datos WEG_NC2 para cinco estados.....	111
Figura 8.28. Matriz de confusión y parámetros asociados de los datos WEG_NC1 para cinco estados.....	112
Figura 8.29. Matriz de confusión y parámetros asociados de los datos AB1_NC2 para cinco estados.....	112
Figura 8.30. Matriz de confusión y parámetros asociados de los datos AB1_NC1 para cinco estados.....	113
Figura 8.31. Matriz de confusión y parámetros asociados de los datos AB2_NC2 para cinco estados.....	113
Figura 8.32. Matriz de confusión y parámetros asociados de los datos AB2_NC1 para cinco estados.....	114
Figura 8.33. Matriz de confusión y parámetros asociados de los datos AB3_NC2 para cinco estados.....	114

Figura 8.34. Matriz de confusión y parámetros asociados de los datos AB3_NC1 para cinco estados.....	115
Figura 8.35. Matriz de confusión y parámetros asociados de los datos AB4_NC2 para cinco estados.....	115
Figura 8.36. Matriz de confusión y parámetros asociados de los datos AB4_NC1 para cinco estados.	116
Figura 8.37. Matriz de confusión y parámetros asociados de K-Means en los casos RED_NC2, WEG_NC2 y AB1_NC2.....	130
Figura 8.38. Matriz de confusión y parámetros asociados de Hierarchical Clustering en los casos RED_NC2, WEG_NC2 y AB1_NC2.....	131
Figura 8.39. Matriz de confusión de los datos RED_NC2 para técnicas supervisadas.....	133
Figura 8.40. Matriz de confusión de los datos RED_NC1 para técnicas supervisadas.....	134
Figura 8.41. Matriz de confusión de los datos WEG_NC2 para técnicas supervisadas.....	134
Figura 8.42. Matriz de confusión de los datos WEG_NC1 para técnicas supervisadas.....	135
Figura 8.43. Matriz de confusión de los datos AB1_NC2 para técnicas supervisadas.....	135
Figura 8.44. Matriz de confusión de los datos AB1_NC1 para técnicas supervisadas.....	136
Figura 8.45. Matriz de confusión de los datos AB2_NC2 para técnicas supervisadas.	136
Figura 8.46. Matriz de confusión de los datos AB2_NC1 para técnicas supervisadas.	137
Figura 8.47. Matriz de confusión de los datos AB3_NC2 para técnicas supervisadas.	137
Figura 8.48. Matriz de confusión de los datos AB3_NC1 para técnicas supervisadas.	138
Figura 8.49. Matriz de confusión de los datos AB4_NC2 para técnicas supervisadas.	138

Figura 8.50. Matriz de confusión de los datos AB4_NC1 para técnicas supervisadas.	139
--	-----

ANEXO 1.

Figura A1.1. Motor empleado de la marca SIEMENS.....	154
Figura A1.2. Variador de frecuencia WEG CFW-11.....	155
Figura A1.3. Variador de frecuencia Allen-Bradley PowerFlex 40.....	156
Figura A1.4. Freno de polvo magnético y unidad de control de Lucas-Nülle.	157
Figura A1.5. Transductor de corriente Honeywell.....	157
Figura A1.6. Transductor de corriente LEM	158
Figura A1.7. Sistema de adquisición de datos de National Instruments.....	159
Figura A1.8. PC portátil del sistema de adquisición de datos	160

CAPÍTULO 1.

INTRODUCCIÓN

Los motores eléctricos de inducción o motores asíncronos constituyen el principal tipo de motor empleado en la industria moderna. La finalidad de estos motores de corriente alterna es la transformación de energía eléctrica en energía mecánica, destinada a diversos usos dentro del sector como pueden ser en bombas de agua, cintas transportadoras, ventiladores, grúas, etc. Además, también son empleados en la conocida como electromovilidad. La elección de este tipo de motores se debe a su robustez, eficiencia y facilidad de regulación de la velocidad, entre otros.

A pesar de la fiabilidad y robustez de estos motores, no están exentos de la aparición de fallos o averías en los mismos. Estas van a aparecer cuando las características de funcionamiento como la tensión de trabajo, la humedad o la temperatura, adquieran valores diferentes a los nominales. Dichas alteraciones se deben a la presencia de esfuerzos sobre el motor que originan a su vez diferentes fallos sobre las distintas partes de la máquina. Los mismos pueden aparecer en el rotor, estátor, eje o en los rodamientos. Estos últimos representan la parte del motor en la que la presencia de fallos es mayor, siendo parte del estudio del presente Trabajo Fin de Grado (TFG).

La aparición de fallos en este tipo de máquinas, dado su importancia en los procesos productivos, puede suponer inconvenientes como las paradas de producción inesperadas o incluso la destrucción del motor, derivando en pérdidas económicas. Por todo ello, una tarea imprescindible es el mantenimiento de los mismos para así poder arreglar, predecir y/o evitar los problemas anteriores. Existen tres tipos de mantenimiento: el correctivo, el preventivo y el predictivo. El primero de ellos consiste en corregir el fallo ocasionado una vez este se ha producido. El mantenimiento preventivo, por su parte, se basa en revisiones periódicas del estado del motor. El último tipo de mantenimiento, el mantenimiento predictivo, se fundamenta en la monitorización de una característica del motor que permita conocer su estado y así poder actuar debidamente a tiempo evitando fallos o consecuencias mayores. La complejidad e importancia de este tipo de motores origina que le sean aplicados los tres tipos de mantenimiento existentes.

El mantenimiento predictivo, el más sofisticado de los tres, presenta una serie de técnicas para su ejecución. Una de estas técnicas es el Análisis Espectral

de la Corriente o MCSA por sus siglas en inglés, cuyo funcionamiento se basa en la monitorización de la corriente del estátor para la detección de fallos de asimetría de la jaula del motor, excentricidad o fallos en los rodamientos mediante la presencia, en dicha corriente, de frecuencias características de cada uno de los fallos anteriores. En el presente trabajo se empleará la técnica de mantenimiento predictivo descrita para la detección de fallos en los rodamientos del motor, a través de la obtención de datos de la corriente del estátor bajo diferentes estados de los rodamientos. Concretamente se emplean técnicas de Machine Learning enfocadas al mantenimiento predictivo empleando el sistema de cómputo numérico MATLAB 2021.

Machine Learning consiste en dotar de cierto aprendizaje a las máquinas, entrenando algoritmos mediante datos que reflejen el estado del sistema. Siendo capaces, dichos algoritmos, de determinar el estado de nuevos sistemas al introducir los datos de los mismos.

Particularizando al caso de estudio, mediante esta rama de la inteligencia artificial y empleando los datos del motor obtenidos mediante la técnica MCSA, se podría crear un algoritmo que predijera el estado de nuevos motores de inducción al introducir una serie de datos equivalentes y sin la necesidad de la interpretación humana.

Dentro de Machine Learning existen dos tipos de técnicas, las supervisadas y las no supervisadas. Empleando los datos de la corriente del motor indicativos de los diferentes estados de los rodamientos, desde sano hasta destruido y a través de MATLAB, se analizará el comportamiento de ambas técnicas frente a la clasificación de los datos indicados.

Se comprobará la precisión de las técnicas supervisadas y no supervisadas a la hora de clasificar los datos frente a diferentes modos de alimentación del motor y niveles de carga, obteniendo patrones en sus comportamientos, pudiendo comparar ambas técnicas y logrando así conclusiones de las respuestas obtenidas, alcanzando de esta manera el objetivo del presente Trabajo Fin de Grado.

CAPÍTULO 2.

OBJETIVOS

En este capítulo se expondrán el contenido y los objetivos de cada uno de los capítulos que forman el presente Trabajo Fin de Grado.

El capítulo 1 recoge la introducción al TFG. El objetivo de este primer capítulo es dar una idea general sobre el trabajo presente e indicar el propósito del mismo.

El capítulo 3 trata la importancia del motor eléctrico de inducción, su principio de funcionamiento, las diferentes partes que lo constituyen y, por último, los principales tipos de motores de inducción que existen. El objetivo de este capítulo es presentar la máquina de estudio y sus diferentes partes, dando mayor importancia a los rodamientos, ya que constituyen la parte del motor de la que sus fallos se emplearán en el análisis realizado.

El capítulo 4 recopila los diferentes fallos que pueden darse en las partes de un motor de inducción y las causas de los mismos. El objetivo del cuarto capítulo es presentar los fallos que puede tener un motor de inducción y los esfuerzos que los provocan, permitiendo, además, la comprensión del procedimiento seguido para originar los fallos en los rodamientos de estudio.

En el capítulo 5 se explica el mantenimiento destinado a los motores de inducción. Se presentan los tres tipos de mantenimiento existentes, su evolución histórica y sus ventajas e inconvenientes. Además, se muestran algunas de las técnicas de mantenimiento predictivo aplicadas a este tipo de motores. Por último, se estudia el Análisis Espectral de la Corriente para el caso de un motor alimentado mediante un convertidor de frecuencia. El objetivo del capítulo 5 es tratar el mantenimiento que se aplica a los motores de inducción, incluyendo el Análisis Espectral de la Corriente, técnica empleada en este trabajo.

En el capítulo 6 se habla sobre el aprendizaje automático o Machine Learning. Se explica de qué se trata y las dos técnicas en las que se divide, exponiendo algunos de los algoritmos que forman cada una. El objetivo de este sexto capítulo es presentar el concepto de Machine Learning y explicar el funcionamiento de las técnicas supervisadas y no supervisadas, junto con el de sus algoritmos, pudiendo comprender el estudio realizado al

comportamiento de ambas técnicas para diagnosticar el estado de motores de inducción.

En el capítulo 7 se trata el procedimiento de la toma de los datos indicativos del estado del motor en cuestión, necesarios para realizar los diferentes análisis. Se indican los elementos para la toma de dichos datos, las configuraciones de alimentación y carga posibles en dicha tarea, los diferentes estados del rodamiento a tener en cuenta y el número de ensayos realizados para cada estado. Además, se expone el tratamiento que se da a los datos para poder trabajar con el sistema de cómputo numérico MATLAB versión R2021b. El objetivo de este capítulo es presentar el contenido de los datos del estudio, su obtención y tratamiento, pudiendo así comprender el uso de los mismos para la obtención de resultados.

En el capítulo 8 se muestran los resultados obtenidos del empleo de las técnicas supervisadas y no supervisadas para la clasificación de los datos del motor, indicando algunas observaciones del comportamiento de las mismas. Se presentan diferentes posibilidades a la hora de establecer el número de estados del motor con el objetivo de completar el estudio. El objetivo es recopilar pruebas e información del comportamiento de ambas técnicas para poder así sacar conclusiones y lograr el fin del presente trabajo.

En el capítulo 9 se recopilan las conclusiones obtenidas del estudio realizado.

En el capítulo 10 se recogen las referencias bibliográficas empleadas para la realización del TFG.

El Anexo 1 reúne los diferentes elementos empleados para la realización de los ensayos al motor de inducción y la toma de datos de la corriente del estátor.

En el Anexo 2 se muestran los diferentes scripts del sistema de cómputo numérico MATLAB versión R2021b empleados en el presente trabajo.

CAPÍTULO 3.

MOTORES DE INDUCCIÓN.

3.1. DESCRIPCIÓN E IMPORTANCIA.

La energía eléctrica constituye un bien imprescindible para la vida tal y como la conocemos. Ya sea para la producción de calor, de luz, para la carga de baterías, para generar señales mediante sistemas electrónicos o para la producción de energía mecánica. Es para este último fin, para la conversión de energía eléctrica en energía mecánica, para el que se destina la mayor parte de la electricidad generada.

La generación de electricidad se lleva a cabo empleando máquinas síncronas principalmente. Mientras que la obtención de energía mecánica, por su parte, se realiza mediante motores de inducción o asíncronos, en la mayoría de los casos.

Los motores de inducción, justificado por lo expuesto anteriormente, representan una de las máquinas más importantes e imprescindibles a nivel industrial. Se estima que en torno al 90% de los motores presentes en la industria son de este tipo. La apuesta por estos motores se debe a su robustez, eficiencia, fiabilidad y fácil regulación de velocidad, mediante un variador de frecuencia.

3.2. PRINCIPIO DE FUNCIONAMIENTO

Como ya se ha comentado, un motor de inducción transforma la energía eléctrica en energía mecánica. Concretamente, alimentando el estátor (parte fija del motor), conseguimos el movimiento giratorio del rotor (parte móvil del motor). Para conseguir esto, en un motor trifásico, se dan lugar una serie de sucesos definidos a continuación.

En primer lugar, al alimentar con corriente alterna trifásica y equilibrada el estátor del motor, se origina un campo magnético giratorio. Este fenómeno se basa en el hecho de que el paso de una corriente por un conductor origina un campo magnético que lo rodea, cuyo sentido depende del sentido de la corriente por el conductor. Cada fase de la corriente trifásica circulará por los devanados del estátor, generando en sus conductores campos magnéticos cuyo valor va a ir variando, al tiempo que evolucionan las tres fases de las corrientes, desfasadas 120°.

El resultado final, como ya se ha dicho, es un campo magnético giratorio. La velocidad de giro de este, conocida como velocidad de sincronismo, depende de la frecuencia de la onda de alimentación y presenta la siguiente forma:

$$n_s = \frac{60 f}{p} \quad (3.1)$$

Donde:

n_s es la velocidad de sincronismo.

f es la frecuencia de la corriente de alimentación del motor.

p es el número de pares de polos del motor.

El estátor envuelve al rotor del motor. Es decir, un conductor se encuentra en el seno de un campo magnético variable, por lo que un flujo magnético varía debido al giro. Según la Ley de Faraday, se inducirá una fuerza electromotriz en el conductor:

$$\varepsilon \text{ (f. e. m)} = -N \frac{d\Phi}{dt} \quad (3.2)$$

Siendo:

ε (f. e. m) es la fuerza electromotriz inducida en el conductor.

N es el número de espiras de la bobina donde se induce la f.e.m.

Φ es el flujo magnético del estátor.

Por lo tanto, en el rotor del motor se va a inducir una tensión proporcional al número de espiras del mismo y a la variación del flujo magnético del estátor respecto al tiempo. Tendrá sentido contrario al campo magnético giratorio que la origina.

La tensión inducida provoca una corriente en el conductor, es decir, en el rotor. De esta manera existe una corriente eléctrica en el seno de un campo magnético (el generado por el estátor). Según la Ley de Laplace, aparecerán un par de fuerzas en el conductor, que provocarán el giro del rotor.

$$F = I \cdot (L \times B) \quad (3.3)$$

Donde:

F es la fuerza que aparece en el conductor.

I es la intensidad que circula por el conductor.

L es la longitud del conductor.

B es la intensidad de campo magnético.

La velocidad de giro de rotor, de igual valor que la velocidad de giro del campo magnético que se origina en el rotor como consecuencia de las corrientes inducidas, en este tipo de motores, va a ser ligeramente inferior a la de sincronismo. Motivo por el cual se conoce a este tipo de motores como motores asíncronos, además de como motores de inducción. Se define la velocidad de giro del rotor de la siguiente manera:

$$n = n_s (1 - s) \quad (3.4)$$

Siendo:

n la velocidad de giro del rotor.

n_s la velocidad de sincronismo.

s el deslizamiento.

El deslizamiento, es la diferencia relativa entre la velocidad de giro del campo magnético (velocidad síncrona) y la velocidad de giro del rotor:

$$s = \frac{n_s - n}{n_s} \quad (3.5)$$

En vacío el deslizamiento es muy pequeño, por lo que el rotor va a girar a una velocidad semejante a la síncrona. Por lo tanto, no va a existir mucha variación de flujo entre estátor y rotor. Siendo la corriente inducida en el rotor, en consecuencia, muy pequeña. La necesaria para vencer el par en vacío y hacer girar el motor.

Frente a un par externo procedente de una carga que controle el motor, el rotor disminuye su velocidad. La decremента lo justo para que la corriente inducida

genere un par electromagnético, debido a la diferencia de rotación entre el campo magnético del estátor y el propio rotor, compensando así el par externo con uno de igual valor y sentido contrario. Accionando la carga como resultado.

Cuanto mayor sea la carga a accionar, mayor ha de ser la diferencia entre velocidades. Siendo por lo tanto mayor el deslizamiento y menor la velocidad del rotor. Será así mayor la variación de flujo magnético, originando una mayor fuerza electromotriz inducida. Esta originará una mayor corriente inducida, dando lugar a mayor par motor para abordar el par externo.

3.3 CIRCUITO EQUIVALENTE

El circuito equivalente exacto de un motor de inducción para régimen estacionario senoidal es el siguiente:

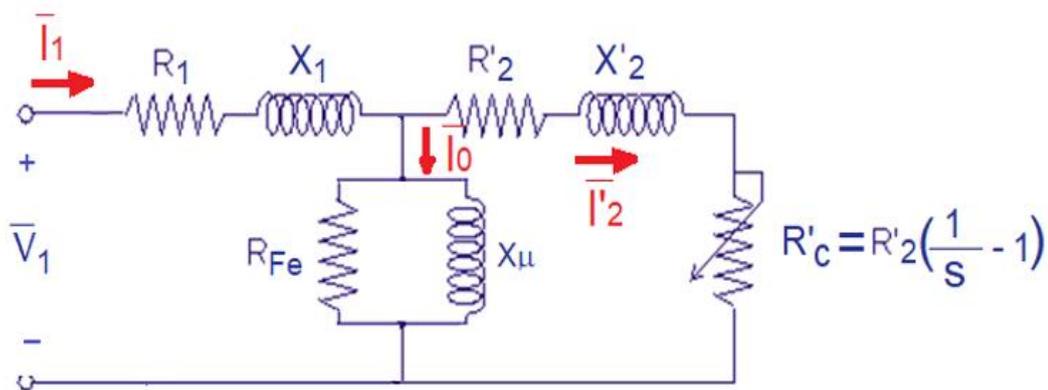


Figura 3.1. Circuito equivalente exacto de un motor de inducción en régimen estacionario senoidal. [3]

Donde:

R_1 → Resistencia por fase del estátor.

R'_2 → Resistencia por fase del rotor reducida al estátor.

X_1 → Reactancia de dispersión del estátor.

X'_2 → Reactancia de dispersión del rotor reducida al estátor.

R'_c → Resistencia de la carga reducida al estátor.

X_μ → Reactancia magnetizante.

R_{Fe} → Resistencia representativa de las pérdidas en el hierro.

\bar{I}_1 → Corriente del estátor.

\bar{I}'_2 → Corriente inducida en el rotor.

\bar{I}_0 → Corriente de vacío.

\bar{V}_1 → Tensión de fase aplicada al estátor.

3.4. COMPONENTES PRINCIPALES

Para poder abordar de manera exitosa labores de mantenimiento de motores, además de conocer su funcionamiento, explicado en el apartado anterior, es necesario conocer las partes de las que están formados. En este apartado, por lo tanto, se van a mostrar las partes fundamentales de los motores de inducción, para poder entender dónde y por qué pueden aparecer fallos en el motor.

3.4.1 ESTATOR.

Las dos partes fundamentales de los motores de inducción, así como de cualquier máquina rotativa de conversión electromecánica, son el rotor y el estátor. El estátor constituye la parte fija y el inductor de la máquina, es decir, al alimentarlo con corriente trifásica o monofásica, induce una corriente en el rotor. Siendo este último la parte móvil y el inducido, por lo tanto.

El estátor está formado por una serie de chapas de acero al silicio, en las cuales se sitúa un devanado trifásico, en el caso de un motor trifásico, gracias a la presencia de unas ranuras en la periferia interior de dichas chapas. Al alimentar con corriente alterna, se consigue el campo magnético giratorio precisado, tal como ya se explicó.



Figura 3.2. Estátor de un motor jaula de ardilla. [3]



Figura 3.3. Estátor de un motor de rotor cilíndrico. [3]

3.4.2. ROTOR.

El rotor es el encargado de obtener la energía de salida, es decir, es donde se transforma la energía eléctrica en mecánica. Está formado por un conjunto de láminas de acero al silicio, con forma de cilindro, con unas ranuras en la superficie exterior. En estas, irá incrustado o bien un devanado o bien una serie de conductores conectados en cortocircuito, según el tipo constructivo.

3.4.3. CARCASA

Constituye la estructura que rodea al estátor y protege tanto a este como al rotor y demás elementos del interior del motor. Presenta patas de fijación y tornillos necesarios para su instalación a una superficie y puede estar fabricada de acero o aluminio, entre otros materiales.



Figura 3.4. Carcasa de un motor de inducción trifásico. [12]

3.4.4. DEVANADOS.

Los devanados o bobinados son los circuitos eléctricos del motor, donde se crea el campo magnético y donde se inducen las corrientes. Pueden ser de materiales como cobre, aleaciones de cobre o aluminio. En los motores de inducción son de tipo abierto, es decir, presentan principio y final.

Respecto al tipo de bobina, existen devanados excéntricos y concéntricos. El primero se caracteriza por estar formado por bobinas de igual anchura, desfasadas entre sí en el espacio. El segundo, por su parte, presenta bobinas concéntricas que comparten eje.

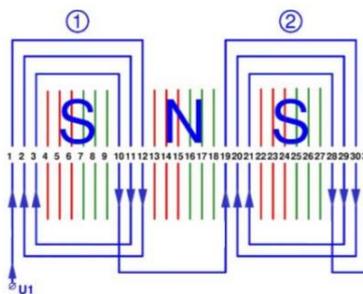


Figura 3.5. Devanados concéntricos. [3]

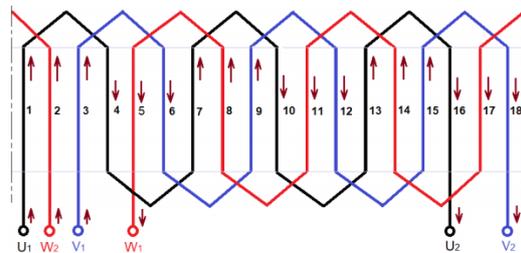


Figura 3.6. Devanados excéntricos. [3]

3.4.5. PLACA DE BORNES.

La placa de bornes está formada de material aislante, como resina, portando los terminales de cada uno de los devanados del estátor. Por lo tanto, en el caso de un motor trifásico, presentará seis conexiones. La razón por la que los terminales de una misma fase no se encuentran enfrentados en la placa, es para facilitar la conexión del motor, en triángulo o en estrella.

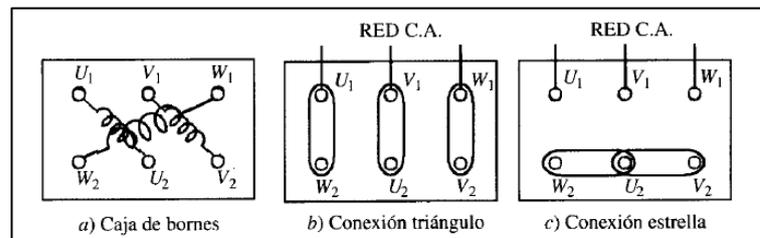


Figura 3.7. Placa de bornes. [1]

3.4.6. ENTREHIERRO.

Espacio de aire que existe entre el rotor y el estátor del motor. El flujo magnético creado por el estátor ha de atravesar el entrehierro para poder inducir corrientes en el rotor. Al estar formado por aire, introduce una reluctancia magnética, es decir, presenta una resistencia al paso del flujo magnético. Por lo tanto, se busca que el entrehierro sea lo menor posible, siendo del orden de milímetros. Debido a la reducida separación, entre rotor y estátor, es necesaria la constante monitorización del entrehierro, al ocasionar graves daños al motor si ambas partes entraran en contacto.

3.4.7. EJE.

Consiste en el elemento unido al rotor que transmite la energía mecánica giratoria que este desarrolla a la carga a accionar por el motor.

3.4.8. RODAMIENTOS.

Los rodamientos son elementos rotativos cuya misión es unir elementos fijos con rotativos. En un motor de inducción sujetará el rotor y lo unirá al estátor. De igual manera, soportará los esfuerzos radiales o axiales que se originan en el rotor, derivándolos del eje al bastidor del motor. Están formados por dos cilindros concéntricos en cuyo interior se sitúan bolas o rodillos girando libremente. Representa un elemento fundamental en todo tipo de motores, siendo el elemento de estudio del presente trabajo.

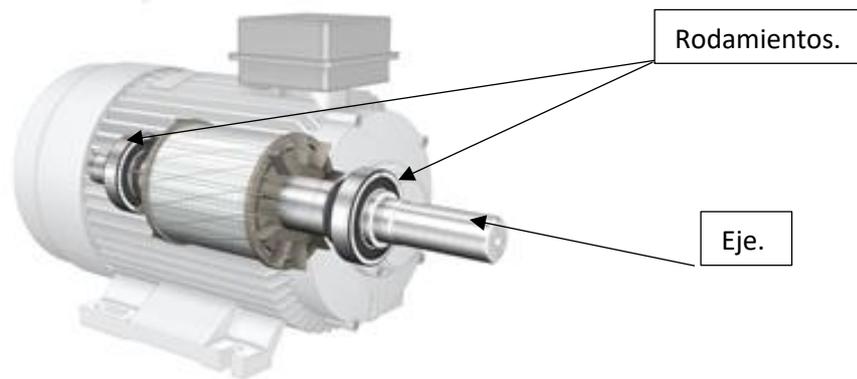


Figura 3.8. Rodamientos y eje en motor jaula de ardilla. [10]

Los principales tipos de rodamientos son los siguientes:

Rodamientos rígidos de bolas.

Constituyen un tipo de rodamiento muy habitual en todo tipo de motores eléctricos. Se caracterizan por su funcionamiento silencioso, presentan baja fricción, pueden trabajar a altas velocidades y soportan cargas radiales, axiales y combinadas.



Figura 3.9. Rodamiento rígido de bolas. [10]

Rodamiento de rodillos cilíndricos.

Este tipo de rodamientos soportan grandes esfuerzos radiales y son capaces de aguantar una velocidad relativamente alta. Se emplean en motores eléctricos medianos o grandes con transmisión por engranajes o correa.



Figura 3.10. Rodamiento de rodillos cilíndricos. [10]

Rodamientos INSOCOAT.

Se particularizan por presentar aislamiento eléctrico. Pueden estar formados por bolas o por rodillos cilíndricos. Suponen un aumento del tiempo productivo del motor y su confiabilidad, impidiendo la erosión eléctrica.



Figura 3.11. Rodamientos INSOCOAT. [10]

Rodamientos híbridos.

Los aros de estos rodamientos están fabricados de acero, mientras que los elementos rodantes de nitruro de silicio. Esto permite que sean unos excelentes aislantes y funcionar a mayores velocidades con mayor tiempo de vida útil frente a rodamientos fabricados solo de acero. Otra propiedad es que frente a vibraciones presentan muy buen comportamiento. De nuevo pueden estar formados por bolas o rodillos cilíndricos.



Figura 3.12. Rodamientos híbridos. [10]

Rodamientos de bolas de contacto angular.

Presentan gran resistencia frente a carga axial y son capaces de funcionar a altas velocidades. Su construcción puede realizarse con una o dos hileras, aumentando la carga axial soportable con esta última opción. Por último, se utilizan, entre otras aplicaciones, en motores verticales cuando los rodamientos rígidos de bolas no pueden soportar los esfuerzos axiales.



Figura 3.13. Rodamientos de bolas de contacto angular. [10]

Rodamientos de rodillos a rótulas.

En este tipo de rodamientos, los rodillos se disponen frente a las cargas de la manera más adecuada, siendo guiados por un anillo flotante. De este modo, producen menos calor y son capaces de aguantar cargas muy grandes. Se emplean, por lo tanto, en grandes motores eléctricos.



Figura 3.14. Rodamiento de rodillos a rótulas. [10]

Rodamientos axiales de rodillos a rótulas.

La característica principal es su capacidad de abordar grandes esfuerzos axiales, siendo los que más soportan. Además, puedes aguantar cargas radiales simultáneamente y son autoalineables. Se utilizan en grandes máquinas eléctricas con enormes esfuerzos axiales



Figura 3.15. Rodamiento axial de rodillos a rótulas. [10]

3.5 TIPOS DE MOTORES DE INDUCCIÓN.

En el apartado presente, se expondrán los principales tipos de motores de inducción. A saber: motor de inducción de jaula de ardilla, motor de rotor bobinado, motor de inducción monofásico y motor de inducción de doble jaula de ardilla.

3.5.1. MOTOR DE INDUCCIÓN DE JAULA DE ARDILLA.

Se caracteriza porque su rotor está formado por un conjunto de conductores de cobre o aluminio conectados en cortocircuito mediante dos anillos laterales. La forma final se asemeja a una jaula de ardilla, de ahí su nombre. Dichos conductores se encuentran incrustados en un apilamiento cilíndrico de chapas de acero, cuyo objetivo es favorecer el flujo magnético. En máquinas pequeñas se emplean técnicas de fundición de aluminio para obtener en una sola pieza las barras y los anillos laterales, reduciendo costes de producción.

Representa el tipo de motor de inducción más empleado en la industria, debido a ser barato, eficiente, robusto y fiable. Además, su construcción es sencilla, el coste de mantenimiento es reducido y el peso es menor en comparación con otros motores. Algunas de sus aplicaciones son el uso en ventiladores, tornos, fresadoras, etc. Presenta desventajas como el reducido par de arranque o la necesidad de un variador de frecuencia para poder modificar la velocidad del motor.

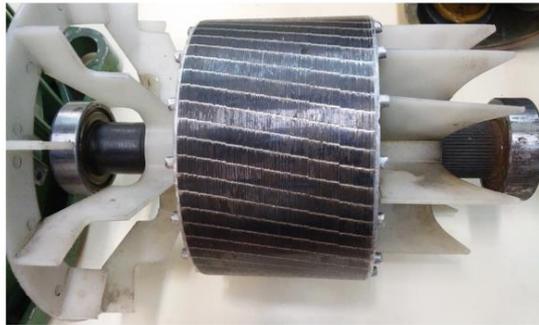


Figura 3.16. Rotor de motor jaula de ardilla. [3]

3.5.2. MOTOR DE INDUCCIÓN DE ROTOR CILÍNDRICO.

En este tipo de motor, también conocido como motor de inducción de anillos deslizantes, presenta un rotor formado por un devanado trifásico, similar al del estátor. Las tres fases se conectan por un lado en triángulo, mientras que por el otro se conectan a unos anillos aislados entre sí.

Se caracterizan por presentar alto par de arranque, por lo que son recomendados cuando la carga presente alto par resistente. Además, el control de velocidad es sencilla mediante la variación de unas resistencias externas conectadas a los anillos antes comentados. Se emplean en montacargas, grúas, etc. Sus inconvenientes son que precisa gran mantenimiento, su fabricación es más compleja y costosa y presenta menor eficiencia frente al motor de jaula de ardilla.



Figura 3.17. Rotor de motor de rotor cilíndrico. [3]

3.5.3. MOTOR DE INDUCCIÓN DE DOBLE JAULA DE ARDILLA.

Se caracteriza, como su nombre indica, por tener dos rotores de jaula de ardilla concéntricos, uno externo y otro interno. Ambas jaulas están separadas por medio de una fina rendija, cuya misión es incrementar los flujos de dispersión magnética de la jaula interior, logrando así una gran resistencia y baja reactancia en la jaula exterior. La jaula interna, por su parte, tendrá alta reactancia y baja resistencia.

La corriente circulará en el rotor en función de la impedancia que se encuentre. Durante el arranque, la frecuencia de rotor y estátor coinciden, siendo mayores las reactancias que las resistencias. Como la reactancia por la jaula exterior es menor que la de la interior, circulará por esta la mayoría de la corriente. A velocidad normal de funcionamiento, la frecuencia del rotor es despreciable, siendo mayores las resistencias, y por lo tanto, circulando por la jaula interior la mayor parte de la corriente. Por lo tanto, la jaula exterior contribuirá más al arranque, mientras que la interior, al funcionamiento en régimen permanente. Con lo anterior se consiguen altos pares durante el arranque y buen rendimiento con velocidad nominal.

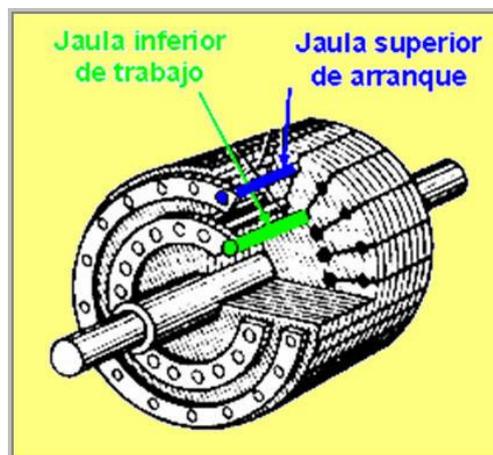


Figura 3.18. Rotor de motor doble jaula de ardilla.[13]

3.5.4. MOTOR DE INDUCCIÓN MONOFÁSICO.

El motor de inducción monofásico está formado por un rotor de jaula de ardilla y un estátor alimentado con corriente alterna monofásica.

Una particularidad de este tipo de motores es que presenta par de arranque nulo, es incapaz de arrancar por sí solo. Esto se debe a que las dos corrientes que se inducen en el rotor son opuestas, originando un par resultante nulo. Sin embargo, si se provoca el giro del motor en algún sentido, surgirá un par de arranque que permitirá el giro del motor si este par es superior al resistente. Este impulso al motor para conseguir el giro se realiza mediante procedimiento eléctricos, a través de un devanado bifásico en el estátor.

Su rango de potencia es limitado, por debajo de 1CV, siendo empleado principalmente en instalaciones domésticas como en lavadoras o frigoríficos.



Figura 3.19. Motor de inducción monofásico. [11]

CAPÍTULO 4.

FALLOS MÁS COMUNES EN LOS MOTORES DE INDUCCIÓN.

En este cuarto capítulo se mostrarán las principales maneras en las que puede fallar un motor de inducción. Se analizarán una por una las principales partes que constituyen el motor, exponiendo los fallos ocasionados en las mismas y sus causas. Haciendo un estudio con mayor profundidad de las averías asociadas a los rodamientos, siendo estos, parte del tema de estudio del presente trabajo.

El motor de inducción, como ya se ha comentado, debe su gran importancia en el sector industrial, entre otros aspectos, a su robustez y fiabilidad. Aun así, como es lógico, sufre averías. Estas aparecen cuando el motor se somete a esfuerzos mayores a los nominales o durante un tiempo mayor al previsto. Es necesario diferenciar los fallos que surgen en el motor cuando las ondas de corriente y tensión siguen funciones senoidales, cuando existen alteraciones en las mismas y cuando el motor está alimentado a través de un convertidor de frecuencia. Esto último se realiza con el objetivo de modificar la velocidad del motor. Se juega con la frecuencia de la onda de alimentación debido a la relación directa de esta con la velocidad del motor.

En el presente capítulo sólo se analizarán los fallos ocasionados en el primero de los tres casos anteriores. Así, en los siguientes apartados se expondrán algunos fallos en un motor de inducción cuando las ondas de tensión y corrientes son senoidales, obviando en algunos casos aquellos originados por defectos de fabricación.

4.1. ESFUERZOS EJERCIDOS SOBRE EL MOTOR.

Un motor de inducción, como cualquier otro dispositivo, presenta una serie de características que han de estar en cierto rango para un correcto funcionamiento. En este caso, estas características son: la tensión de trabajo, la altitud, la humedad, el par de carga, la temperatura de funcionamiento, etc. Si estas especificaciones se ven alteradas, el motor es sometido a una serie de esfuerzos para los que no está diseñado, pudiendo causar una avería en el mismo.

La causa de dichos esfuerzos presenta diversa naturaleza, afectando a diferentes partes del motor en cada caso. Al conjunto de causas que originan averías en los motores se lo conoce como TEAM, es decir, factores térmicos, factores eléctricos, factores ambientales y factores mecánicos.

En la tabla 4.1 se muestran algunos ejemplos de cada uno de los anteriores factores que afectan al motor. Todos ellos pudiendo afectar al estátor, al rotor, a los rodamientos y al eje del motor, aspectos que se analizarán con mayor detalle en los siguientes apartados.

FACTOR	TIPOS		
TÉRMICO	Envejecimiento	Sobrecarga	
ELÉCTRICO	Efecto Corona	Transitorios	Dieléctricos
AMBIENTAL	Humedad	Químicos	Desgaste
MECÁNICO	Golpe del rotor	Movimiento de bobinas	

Tabla 4.1. Factores que afectan al motor y sus consecuencias [15]

4.2. FALLOS EN EL ESTÁTOR.

Dentro de los fallos originados en el estátor del motor, la mayoría suceden en el sistema aislante. Podemos distinguir fallos en el núcleo magnético y fallos en el aislamiento del bobinado del estátor

4.2.1. FALLOS EN EL NÚCLEO DEL ESTÁTOR.

Las diferentes chapas magnéticas que forman el núcleo del estátor han de estar aisladas entre sí. Un deterioro de este aislamiento puede ocasionar corrientes interlaminares ocasionando un posible sobrecalentamiento del núcleo. Pudiendo dañar además el aislamiento de las bobinas del propio estátor.

El origen de estos defectos puede deberse a la intrusión de objetos ajenos al motor que dañen el aislamiento o a una excesiva vibración que dé lugar al rozamiento entre las distintas láminas, con idéntico resultado.

4.2.2. FALLOS EN EL AISLAMIENTO DEL BOBINADO DEL ESTÁTOR.

De manera general, los fallos que aparecen en el aislamiento de los devanados del estátor se deben a acciones conjuntas de varios esfuerzos. Dichos esfuerzos, ya mostrados en la tabla 4.1, son de origen térmico, eléctrico, mecánico y ambiental.

ESFUERZOS EN LOS DEVANADOS DEL ESTÁTOR.

En los siguientes apartados, se expondrán algunos tipos de dichos esfuerzos.

ESFUERZOS TÉRMICOS.

Los esfuerzos térmicos ocasionan diversos efectos sobre los aislantes eléctricos de los devanados. Esto se justifica por la existencia de un límite de temperatura soportable por los mismos. Al superar dicho límite, los aislantes comienzan a perder sus propiedades.

En la tabla 4.2 se muestran las temperaturas máximas admisibles según la clase de aislamiento.

Clase de aislamiento	A	E	B	F	H	200	220	250
Temperatura máxima (°C)	105	120	130	155	180	200	220	250

Tabla 4.2. Clases de aislamientos. [15]

Algunos de estos efectos, son:

Envejecimiento del aislamiento.

Una de las consecuencias que los esfuerzos térmicos ocasionan sobre los aislantes es el envejecimiento del mismo. En este proceso, los esfuerzos térmicos se consideran, entre otros que lo causan, los principales.

La vida útil del aislamiento eléctrico sometido a cierta temperatura puede calcularse mediante la Ley de Arrhenius:

$$L = A e^{-bT^a} \quad (4.1)$$

Donde:

L es la vida del aislamiento, en horas.

A y b son constantes dependientes de la clase térmica del aislamiento.

T^a es la temperatura absoluta de funcionamiento.

La influencia de la temperatura sobre la vida del aislamiento, además de con la ley anterior, se puede observar a través de la ley de Mottlinger. Esta defiende que por cada aumento de 10°C en la temperatura de manera continuada, la vida del aislante se reduce a la mitad. Estudios más recientes por parte del EPRI (Electric Power Research Institute) en 1985 concluyen que el aumento o disminución de la temperatura de trabajo provoca la disminución o aumento de la vida útil atendiendo a la clase de aislamiento.

Así, para la clase de aislamiento F el incremento de temperatura que ocasiona la disminución de la vida útil a la mitad es entre 14°C y 8°C. Siendo entre 9.3°C y 8°C para la clase H.

Deslizamiento entre las bobinas y el material aislante.

El material aislante y el cobre del que están formadas las bobinas se dilatan a diferente temperatura. En el interior del motor se ocasionan variaciones de temperatura que dan lugar, a partir de lo anterior, al deslizamiento de las capas de aislantes sobre las bobinas. El resultado es una fricción entre ambas que llegan a causar el desgaste e incluso la rotura del aislante.

Sobrecargas térmicas.

Este último fenómeno que disminuye la vida del aislamiento de los devanados del estátor puede deberse a algunas causas nombradas a continuación:

- Desequilibrios de tensión entre las fases del estátor.
- Aumento de la temperatura ambiente.

- Mala Ventilación.
- Variación de la tensión con la que se alimenta el motor.



Figura 4.1. Motor dañado por sobrecargas térmicas. [14]

ESFUERZOS ELÉCTRICOS.

Este segundo tipo de esfuerzo puede ocasionar algunos problemas en el aislamiento del estátor, como pueden ser los siguientes:

Aparición de descargas parciales. Si el aislamiento pierde parte de sus capacidades como aislante o se origina una degradación de las capas del mismo, pueden aparecer pequeños huecos en su interior. Al aplicar la tensión de trabajo, si esta supera la rigidez dieléctrica del aire que se encuentra en los huecos anteriores, dicho aire pasa a ser conductor. Originándose así pequeñas descargas, que si son persistentes pueden dañar o destruir el aislamiento de la zona en cuestión.

Efecto “tracking”. Se manifiesta por la presencia de humedad y sustancias como polvo y suciedad sobre el aislamiento. Estas crean un camino a través del cual circula la corriente y a su paso, aumenta la temperatura del aislamiento. Provocando así su degradación.

Efecto Corona. Constituye un tipo de descarga parcial que aparece entre conductores cuando la tensión aplicada es mayor a la rigidez dieléctrica del gas que los separa. Se provoca así la ionización de dicho gas y la aparición de una capa visible alrededor de los conductores. En los motores de inducción, este fenómeno suele manifestarse en las cabezas de bobinas y puede ocasionar la aparición de un arco eléctrico entre conductores como consecuencia de la ionización del aire. Deteriorando o destruyendo así los aislamientos.

Para evitar este efecto, se necesita la uniformidad del campo eléctrico sobre los aislamientos. Esto se consigue dando una pintura semiconductora a los mismos.

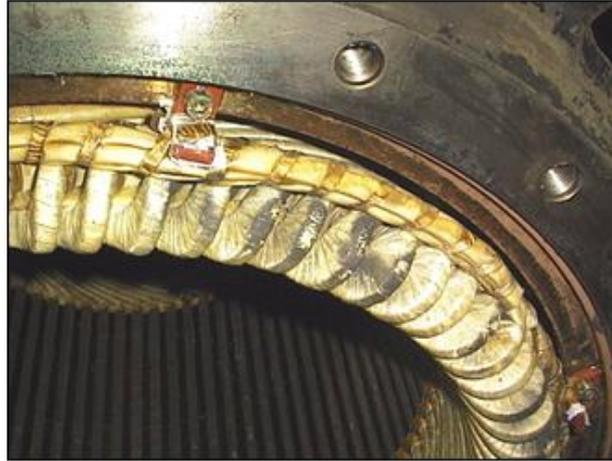


Figura 4.2. Aislamiento perforado por Efecto Corona. [15]

ESFUERZOS MECÁNICOS.

Se distinguen los siguientes esfuerzos de tipo mecánico que pueden afectar a los aislamientos de los devanados.

Movimiento de bobinas. Es un problema habitual en las máquinas eléctricas consistente en el afloje de la sujeción de las bobinas del estátor. Originando el movimiento de estas, incluso del orden de milímetros en grandes máquinas. La causa puede deberse al uso prolongado o a sobrecargas transitorias y las consecuencias son la degradación del material aislante.

Contacto entre estátor y rotor. Justificado por el alineamiento incorrecto de rotor y estátor, por fallos presentes en los rodamientos o por estar doblado el eje.

Vibraciones. Presentes en cualquier máquina eléctrica en funcionamiento, pueden acarrear consecuencias como la fractura del material aislante o el roce de bobinas mal sujetas con otros elementos.

Presencia de objetos externos. En ocasiones pueden introducirse objetos externos a través del entrehierro. Estos casi siempre provienen del circuito de ventilación. Provocan daños no solo en los aislamientos sino también en el cobre de las propias bobinas de rotor y estátor, anillos de cortocircuito, entre otros.

También es posible que elementos sueltos o fuera de su posición correcta del propio motor ocasionen daños a los elementos antes comentados, ya sean tornillos, chapas, etc.

ESFUERZOS AMBIENTALES.

Por último, se indican dentro de este tipo de esfuerzos algunos de los más habituales.

Contaminación. La presencia de agentes como el polvo, la suciedad y la condensación del agua o aceite sobre la superficie del aislamiento trae ciertas consecuencias. Estas son, por un lado, la disminución de la disipación de calor producido en las bobinas, ocasionando un aumento de la temperatura y, por tanto, una destrucción del aislamiento. Por otro lado, como ya se comentó en un apartado previo, la capa de suciedad permite el paso de la corriente, con el mismo resultado anterior.

Alta altitud. Este factor influye en el deterioro del motor debido al calentamiento del mismo. Por encima de los 1000 metros de altitud el aire disminuye sus propiedades refrigerantes, provocando la necesidad de reducir la potencia nominal del motor para evitar su deterioro. En este sentido, la norma CEI 60034-1 indica que los motores han de trabajar en condiciones de potencia nominal si se encuentran por debajo de 1000 metros de altitud y con una temperatura ambiente entre 15°C y 40°C.

Elevada o baja temperatura ambiente. En el caso de que los motores trabajen a una temperatura muy elevada, por encima de los 40°C, será necesario, como se indicó en el apartado anterior, reducir su potencia nominal.

En el caso contrario, en el que trabajen a una temperatura muy baja, por debajo de los -15°C, pueden aparecer problemas en los rodamientos o una excesiva condensación, entre otros problemas. Necesitando emplear una lubricación adecuada y sistemas de drenaje adicional.

FALLOS EN LOS DEVANADOS DEL ESTÁTOR.

En los apartados anteriores se han explicado algunos de los esfuerzos que originan fallos en los devanados del estátor. A continuación, se exponen algunos de estos fallos y sus consecuencias.

Cortocircuito entre fases. Tiene su origen en la presencia de objetos externos, de contaminantes, por vibraciones o picos de voltaje. Las consecuencias son el

fallo del motor y la actuación del sistema de protección que desconecta el motor.



Figura 4.3. Efecto de un cortocircuito entre fases del estátor. [14]

Bobinados quemados. Puede ocurrir por sobrecargas térmicas, como las comentadas anteriormente. Por el bloqueo del rotor, debido a algún fallo en los rodamientos o por falta en una fase del motor, ocasionada por una mala conexión, un mal contacto en un interruptor, en un contactor, etc.



Figura 4.4. Bobinado del estátor quemado por rotor bloqueado. [16]



Figura 4.5. Bobinado del estátor quemado por sobrecargas térmicas. [16]



Figura 4.6. Bobinado del estátor quemado por falta en una fase. [16]

Cortocircuito de fase a tierra. Causados por picos de tensión, provocados estos por descargas eléctricas como rayos o acciones de variadores de frecuencia.



Figura 4.7. Bobinado dañando por picos de tensión. [14]

4.3. FALLOS EN EL ROTOR.

Para abordar este apartado, es necesario distinguir por un lado los fallos en el motor de inducción de jaula de ardilla y, por otro lado, en el motor de rotor cilíndrico.

En el motor de inducción de rotor cilíndrico, al estar constituido el rotor por devanados, de manera similar que el estátor, presentará fallos semejantes. Incluyendo además los problemas ocasionados por las grandes fuerzas centrífugas que aparecen en las cabezas de bobinas.

En cuanto al motor de jaula de ardilla, aunque la misma es mucho más compacta que los devanados, también presentan problemas. Estos suelen deberse a elevadas temperaturas y a grandes fuerzas centrífugas en la unión de los finales de las barras con el anillo de cortocircuito, principalmente durante arranques y cambio de régimen de la máquina. Siendo la causa de los problemas anteriores una mala conexión entre la jaula y el anillo, una errónea elección de los materiales de la jaula o fallos en el proceso de fabricación de la misma.

Además, pueden aparecer fallos por fatiga en la unión de las barras y el anillo de cortocircuito. Estos se deben a variaciones de la velocidad del rotor provocadas por una carga variante, por múltiples arranques y paradas, por inversiones de giro, etc.



Figura 4.8. Fallo por fatiga en la unión de las barras y el anillo de cortocircuito. [14]

FALLOS EN EL NÚCLEO DEL ROTOR.

El paquete magnético del rotor puede sufrir daños debido a elevados esfuerzos mecánicos, al igual que sucede en la jaula y el bobinado como se explicó anteriormente. Los altos ciclos de carga sumados al peso del propio rotor pueden provocar la propagación del agrietamiento de su superficie, con fatales consecuencias.

ESFUERZOS SOBRE LA JAULA DEL ROTOR.

Entre los fenómenos que actúan sobre la jaula del motor, en caso de tratarse de un motor de jaula de ardilla y al igual que aparecían en el estátor, podemos nombrar los siguientes:

Solicitaciones térmicas. Entre ellas se encuentran las sobrecargas térmicas, los desequilibrios térmicos, los puntos calientes y fríos o el chispeo en el rotor.

Estos pueden darse durante el arranque del motor, durante la aceleración, en funcionamiento normal, etc.

Solicitaciones electromagnéticas. Tales como campos magnéticos desequilibrados y la aparición de ruido y vibración electromagnética.

Solicitaciones dinámicas. Dentro se encuentran fuerzas centrífugas, esfuerzos introducidos por el entorno o pares transitorios como los asociados al arranque. Asociadas al régimen de trabajo del motor y a la carga.

Solicitaciones de origen residual. Resultado del proceso de montaje y fabricación en tareas como la colocación del bobinado, apilado de las chapas o soldaduras.



Figura 4.9. Desplazamiento del rotor del eje por un mal montaje. [15]

4.4. AVERÍAS EN EL EJE.

Las causas principales que originan fallos en el eje de las máquinas rotativas son las siguientes:

- Corrosión.
- Fatiga.
- Fracturas.
- Sobrecargas.

En cuanto a las máquinas eléctricas concretamente, el origen del 90% de los fallos en el eje se debe a la fatiga del mismo. Los diferentes tipos de fallos por fatiga pueden deberse a la fatiga flectora, a la fatiga torsional o a la fatiga axial.

Dentro del primer tipo, fatiga flectora, la mayor parte de los fallos tiene origen en la sucesión de esfuerzos de tracción y compresión sobre el eje.

El segundo tipo, la fatiga torsional, es proporcional al par de carga que el motor comunica.

En cuanto al último, la fatiga axial del eje puede venir ocasionado por un fallo en los rodamientos, al tener que soportar estos los esfuerzos en esa dirección.

Todos estos factores que provocan fallos en el eje afectarán en mayor medida en sus puntos débiles, siendo estos las zonas donde varía la sección de manera brusca. Las consecuencias de los mismos son el agrietamiento y la ruptura del eje.



Figura 4.10. Ruptura del eje por fatiga torsional. [14]

4.5. FALLOS EN LOS RODAMIENTOS.

Los rodamientos presentan un periodo de vida útil que viene indicado por el fabricante, debido a la fatiga del mismo con el tiempo. Siempre que el rodamiento trabaje bajo las condiciones indicadas por el propio fabricante, debería cumplir dicho periodo de vida. Sin embargo, existen factores que provocan que este tiempo de vida se reduzca.

4.5.1. PERIODO DE VIDA ÚTIL DE UN RODAMIENTO.

La vida útil de un rodamiento o su duración, viene establecida por el número de revoluciones u horas de funcionamiento que puede realizar sin la aparición de indicios de fallo a velocidad constante.

La AFBMA (Anti-Friction Bearing Manufacturers Association) por su parte, expone la duración de cierto tipo de rodamiento como el número de revoluciones u horas de trabajo con una velocidad constante, que el 90% de los rodamientos del grupo de estudio sean capaces de realizar sin la presencia de señales de fallo por fatiga.

En este sentido, los fabricantes establecen, como ya se indicó, unas condiciones nominales de funcionamiento de carga y velocidad para indicar la duración nominal de la vida de sus productos. Si las condiciones de funcionamiento difieren de las indicadas por el fabricante, mediante la siguiente fórmula se puede calcular la nueva vida útil.

$$L_{10(\text{horas})} = \frac{10^6}{60n_m} \cdot \left(\frac{C}{C'}\right)^{C_p} \quad (4.2)$$

$$L_{10(\text{revoluciones})} = 10^6 \cdot \left(\frac{C}{C'}\right)^{C_p} \quad (4.3)$$

Donde:

$L_{10(\text{horas})}$: manera de indicar el número de horas de funcionamiento de los rodamientos.

$L_{10(\text{revoluciones})}$: manera de indicar la vida útil del rodamiento en revoluciones.

C: carga dinámica considerada por el fabricante, en Newton.

C': nueva carga dinámica en Newton.

n_m : velocidad de rotación, en rpm.

C_p : coeficiente que depende del tipo de rodamiento.

A la hora de calcular la vida útil del rodamiento, es necesario tener en cuenta otros aspectos, además de los que engloba la fórmula anterior. Así, se ha establecido la fórmula denominada “duración de vida modificada” (L_{na}) según la norma ISO 281. Esta fórmula es la siguiente:

$$L_{na} = a_1 \cdot a_2 \cdot a_3 \cdot L_{10} \quad (4.4)$$

Donde:

a_1 es el parámetro de probabilidad de fallo.

a_2 es el factor de influencia del material empleado.

a_3 es el factor de condiciones de trabajo.

En la realidad, los rodamientos presentan una vida mayor a la calculada por estos procedimientos.

4.5.2. ESFUERZOS QUE AFECTAN A LOS RODAMIENTOS.

Los factores que pueden afectar a los rodamientos y provocar una reducción de su duración de vida nominal, son los siguientes:

- Mal dimensionado.
- Montaje incorrecto.
- Carga excesiva en estado estacionario o dinámico.
- Contaminación por agentes externos.
- Vibraciones con el motor parado.
- Incorrecta lubricación.
- Paso de corriente eléctrica.



Figura 4.11. Corrosión en la pista exterior del rodamiento por vibraciones. [14]

A continuación, se entrará en detalle de alguno de estos factores.

Incorrecta lubricación.

La adecuada lubricación de los rodamientos es una tarea crucial para que los mismos no reduzcan su vida útil. Así, es necesario conocer la cantidad de grasas que requiere el rodamiento y la periodicidad con la que aplicar dicho lubricante. Esta información viene recogida en la placa de características del motor en cada caso.

Una correcta lubricación tiene los siguientes objetivos:

- Decrementa el desgaste de los rodamientos al reducir la fricción entre las bolas y las bandas, nunca provocando el deslizamiento.

- Reduce la generación de calor en el rodamiento al disminuir la fricción.
- Disipa el calor que se origina.
- Protege al rodamiento contra la entrada de objetos y contra la corrosión.
- Aumenta la vida del rodamiento.

Las consecuencias de una mala planificación pueden acarrear una mala lubricación por exceso de grasa o por falta de la misma.

Algunas de los problemas que se presentan por falta de grasa son:

- Entrada y depósito de contaminantes externos.
- Degradación de la película aislante con el aumento de fricción y temperatura correspondiente.
- Descascarillado de las pistas del rodamiento con posibilidad de que este se atasque.
- La grasa existente se endurece y pierde sus propiedades.
- Quiebra del rodamiento y contacto entre estátor y rotor.

Por su parte, el exceso de grasa puede originar:

- Incremento de la temperatura por la falta de disipación de calor.
- Resistencia al movimiento del rodamiento por obstrucción.
- Inclusión de grasa en el bobinado del motor pudiendo provocar daños en el mismo.



Figura 4.12. Descascarillado de la pista exterior del rodamiento debido a una incorrecta lubricación. [17]



Figura 4.13. Aparición de grietas debido al aumento de la temperatura por mala lubricación. [17]



Figura 4.14. Destrucción del rodamiento debido a una incorrecta lubricación. [17]

Paso de corriente eléctrica.

El paso de la corriente eléctrica a través de los rodamientos es un problema difícil de detectar cuyas consecuencias son complejas de establecer. Algunos de los efectos son la aparición de cráteres en la superficie del rodamiento bajo la acción de grandes corrientes. También la presencia de estrías paralelas al eje abarcando grandes superficies al atravesar corrientes más débiles. Por último, el deterioro del lubricante y la separación de partículas metálicas del rodamiento.

La causa de este suceso reside en la presencia de tensiones en el eje. Las mismas pueden deberse a la inducción electromagnética o a la presencia de cargas electrostáticas en el eje.

La presencia de tensiones inducidas en el eje se debe a la falta de simetría del circuito magnético que envuelve al mismo. Esto puede originarse por la presencia del fenómeno conocido como excentricidad del rotor, que se

explicará en el siguiente apartado, o a deformaciones en el estátor. Originando así la distribución del flujo de dispersión a lo largo del eje, carcasa y rodamientos, provocando la aparición de una diferencia de potencial en extremos del eje. Otro motivo de alteración del circuito magnético y aparición de tensiones inducidas es la distribución asimétrica de las corrientes en estátor o rotor, ocasionadas por fractura de las barras del rotor, cortocircuitos entre espiras, etc.

Por otro lado, las cargas electrostáticas surgen en el eje, por ejemplo, en turbogeneradores, cuando las gotas de agua inciden sobre las palas de la turbina con el objetivo de accionarla y provocan la acumulación de cargas electrostáticas en dicho eje que comparten turbina y motor.



Figura 4.15. Estrías en la superficie del rodamiento por el paso de la corriente eléctrica. [14]

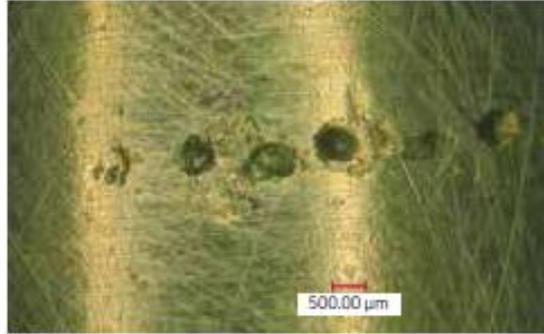


Figura 4.16. Cráteres en la superficie del rodamiento debido al paso de la corriente eléctrica. [17]

4.6. EXCENRICIDAD.

La excentricidad se define como la falta de uniformidad del entrehierro del motor.

Representa un tipo de fallo muy habitual en los motores de inducción. Dentro de los fallos mecánicos en este tipo de motores, que se encuentran entre el 50% - 60% de los fallos, la excentricidad representa un 60%.

Un motor puede trabajar aparentemente sin problemas si sufre de excentricidad, pero la misma puede derivar en complicaciones mucho mayores con consecuencias fatales para el motor.

Los tipos de excentricidad que existen son excentricidad estática, dinámica y mixta.

4.6.1. EXCENRICIDAD ESTÁTICA.

En este tipo de excentricidad, la mínima distancia del entrehierro se presenta constante con el giro.

En la figura 4.16 se presentan dos tipos de excentricidad estática. En la imagen 'a', como vemos, el eje de rotación del rotor no coincide con el centro geométrico del estátor. La causa en este caso es la incorrecta colocación del rotor. En la imagen 'b' por su parte, se ve que el eje de rotación del rotor coincide con el centro geométrico del estátor. La causa en este otro caso es la ovalidad del estátor.

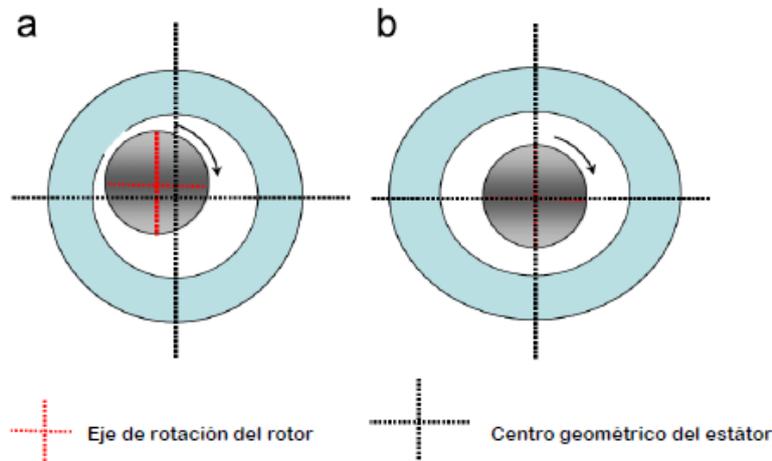


Figura 4.17. Tipos de excentricidad estática. [14]

4.6.2 EXCENRICIDAD DINÁMICA.

En la excentricidad dinámica, la menor distancia del entrehierro no se mantiene constante en el espacio, sino que gira conforme al rotor.

En la figura 4.17 se observan dos ejemplos de este fenómeno. En la imagen 'a' y 'b' coinciden el eje de rotación del rotor y el centro geométrico del estátor. En la imagen 'a' la excentricidad se origina por una mala colocación del rotor, provocando que su centro geométrico no coincida con su eje de rotación. En la imagen 'b', el problema es la ovalidad del rotor.

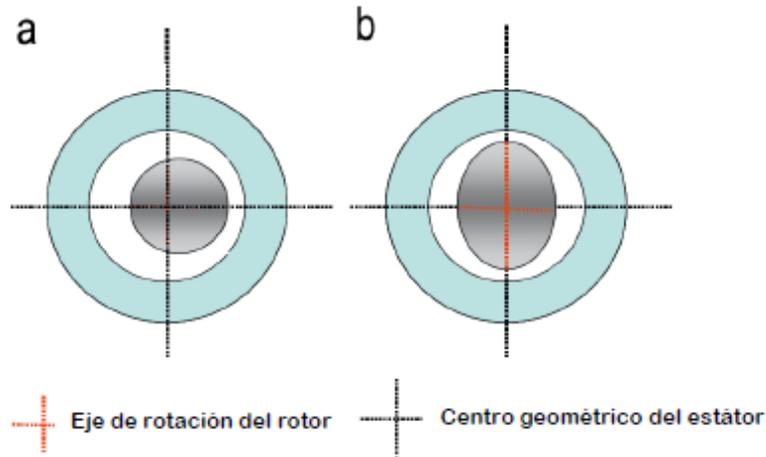


Figura 4.18. Tipos de excentricidad dinámica. [14]

4.6.3. EXCENTRICIDAD MIXTA.

Constituye una mezcla de los dos tipos de excentricidad anteriores. Es normal la presencia de excentricidad mixta en todos los motores. Esto se debe a la posible suma de la excentricidad dinámica durante el funcionamiento del motor a la estática ya presente desde la fabricación y el montaje.

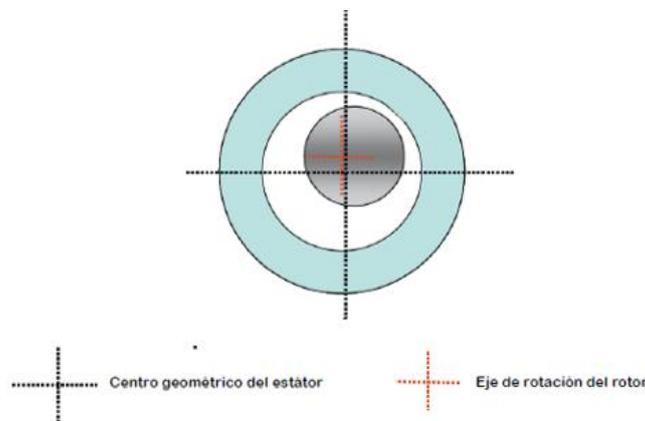


Figura 4.19. Excentricidad mixta. [14]

Algunas causas que provocan la excentricidad son las siguientes:

- Desperfectos en los rodamientos como desgaste, mal montaje, etc.
- Desalineamiento, es decir, mal montaje del rotor y eje dentro del estator.
- Deformaciones del eje.

- La deformidad del eje debido a sobrecargas térmicas.
- Errores en las tolerancias de fabricación.

Entre las consecuencias de la excentricidad, se encuentran:

- Aparición de vibraciones.
- Ruido en el motor, llegando a altos niveles.
- Corriente en los rodamientos.
- Asimetría del circuito magnético del entrehierro.
- Roce del rotor y el estátor con consecuencias fatales.



Figura 4.20. Deterioro de las chapas del estátor por excentricidad. [14]

4.7. CONSECUENCIAS Y COMPARACIÓN ENTRE FALLOS.

De manera general a todos los fallos explicados en capítulos anteriores, se recogen a continuación algunas consecuencias de gran repercusión de la no detección a tiempo de una avería en el motor.

- Interrupción de la producción repentina y sin programar, dando lugar a grandes pérdidas económicas.
- Situaciones peligrosas para la vida de las personas.
- Provocar que los equipos e instalaciones queden inservibles, con su coste asociado.

Se hace visible la enorme importancia del mantenimiento preventivo y predictivo de este tipo de motores, tratados ambos con posterioridad en el capítulo 5.

En este último capítulo del tema 4, además, se comparan los fallos ocasionados en las diferentes partes del motor, empleando la figura 4.:

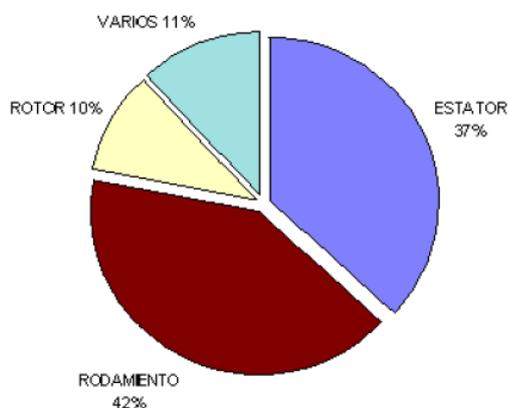


Figura 4.21. Porcentaje de fallos en un motor de inducción. [14]

Como se puede observar, los fallos en el rotor suponen un 11% de los fallos totales. Los que aparecen en el estátor, un 37%. Los que surgen en los rodamientos, por su parte, un 42% y el 11% restantes correspondes a los fallos en el eje, entre otros.

Según las estadísticas, por lo tanto, los fallos en los rodamientos representan el tipo de fallo más frecuentes en los motores eléctricos. Sin embargo, este porcentaje no sería el mismo si tan sólo se tuvieran en cuenta los motores industriales. Considerando todos los motores eléctricos dichas estadísticas son correctas, pero en los motores industriales los fallos son mucho menos frecuentes. Constituyendo por ejemplo el 10% de los fallos en motores eléctricos de tracción.

Lo anterior se debe a que a los motores industriales se les aplica un elevado mantenimiento, con la ejecución de técnicas de mantenimiento preventivo como el reengrase periódico y técnicas de mantenimiento predictivo, como las desarrolladas en el presente trabajo fin de grado. El objetivo es actuar sobre el motor si es necesario antes de que sea demasiado tarde, tal como se explicará más adelante.

CAPÍTULO 5.

MANTENIMIENTO EN MOTORES DE INDUCCIÓN.

El mantenimiento se puede definir como el conjunto de medidas de gestión, administrativas y técnicas para lograr que el dispositivo o sistema en cuestión no presente una alteración de las propiedades que le permiten realizar la tarea para la que está encomendado.

A la hora de desarrollar las funciones de mantenimiento será necesario buscar un equilibrio entre fiabilidad y coste económico. Un escaso mantenimiento del motor acarrea la posible aparición de numerosos tipos de fallos, como los que se mostraron en el capítulo 4, dando lugar a diferentes consecuencias entre las que se encuentran las pérdidas económicas. Un excesivo mantenimiento, por su parte, evitaría la aparición de múltiples fallos, pero supondría un importante coste económico para poder abordarlo.

En este sentido existen tres tipos de mantenimientos: el mantenimiento correctivo, el preventivo y el predictivo. Atendiendo al tipo de dispositivo al que se le efectúe el mantenimiento, la importancia del mismo y su complejidad, se aplicará uno, otro o varios tipos de mantenimiento.

En el caso del motor de inducción, al ser un elemento complejo e imprescindible en la industrial, su mantenimiento se presenta como una tarea crucial cuya estrategia debe englobar los tres tipos de mantenimiento.

5.1. TIPOS DE MANTENIMIENTO.

5.1.1 MANTENIMIENTO CORRECTIVO.

Es el tipo de mantenimiento más básico y antiguo. Surgió por la necesidad de reparar las primeras herramientas, potenciándose durante la revolución industrial a principios del siglo XIX, apareciendo así grupos de personal cualificado para desempeñar estas tareas.

Consiste en permitir el funcionamiento de la máquina hasta que se produzca un fallo en la misma que la impida continuar. Es entonces cuando se actúa sobre la máquina para repararla como sea necesario.

Las ventajas de este tipo de mantenimiento son:

- Reducido coste económico de implementación del método

- Los elementos de las máquinas gastan su vida útil.
- No se necesita material complejo para el mantenimiento.

Los inconvenientes son los siguientes:

- Un fallo localizado puede derivar en uno del conjunto de la máquina.
- Una avería puede suponer la paralización del sistema de producción con un enorme coste asociado.
- No hay interés en buscar la causa del problema, pudiendo esta repetirse.
- Es necesario un gran almacén de repuestos para que no haya una parada de producción excesiva.
- El momento del fallo es imprevisible, pudiendo darse en circunstancias donde los repuestos y el personal son escasos.

Como se ve, los inconvenientes son numerosos y superiores a las ventajas. Sin embargo, este tipo de mantenimiento se emplea frecuentemente. Será destinado, en relación a lo que se dijo en la introducción del capítulo, en máquinas sencillas, no muy costosas, en trabajos tradicionales o en aquellos donde se presenten duplicadas las tareas vitales.

Un ejemplo de este tipo de mantenimiento en motores de inducción sería la sustitución de los rodamientos cuando estos han sido dañados gravemente.

5.1.2. MANTENIMIENTO PREVENTIVO.

Este segundo tipo de mantenimiento, posterior al mantenimiento correctivo, tiene su origen con la aparición de la fabricación en serie, principalmente desarrollada en los Estados Unidos de América a principios del siglo XX. Las graves consecuencias que traían las paradas de producción inesperadas potenciaron la necesidad de este tipo de mantenimiento.

Se basa en la ejecución de una serie de acciones preprogramadas y periódicas sobre el elemento a mantener. Estas acciones pueden ser:

- Añadir consumibles como aceites para el lubricado.
- Limpiar partes de la máquina como pueden ser los filtros de aire.
- Cambiar partes que necesiten su sustitución al cumplirse su tiempo de vida útil, siendo este conocido.
- Inspecciones visuales del conjunto.

Las ventajas que presenta este tipo de mantenimiento son las siguientes:

- No es necesario el almacenamiento de repuestos como ocurría en el caso anterior.
- Organizar el mantenimiento, de manera general, es una tarea sencilla.
- Evita cortes de producción y así un importante gasto.

Por otro lado, algunos inconvenientes son:

- Al aumentar la manipulación del elemento aumentan los errores de montaje.
- En el caso de máquinas que no actúen de manera continuada, será necesario establecer calendarios de actuación adaptados al régimen de funcionamiento, haciendo más compleja la planificación.
- Al cambiar una pieza durante su periodo de vida útil, no se reduce el riesgo de fallo y sí se aumenta el coste al sustituir una pieza que podría seguir funcionando.
- En ocasiones, debido a la complejidad de las máquinas y equipos, con distintos requerimientos, la tarea de planificación puede resultar tediosa a causa de falta de medios disponibles.
- Las paradas de producción necesarias para ejercer este mantenimiento suponen un alto coste, aunque se pueden aprovechar paradas por otro motivo para realizar estas tareas.

Por todo lo anterior, este tipo de mantenimiento será útil cuando el elemento presente un modo de fallo dependiente del tiempo, cuando se deteriore en el tiempo de vida útil establecido y cuando el coste total de la sustitución sea menor al que hubiera provocado un fallo por la no sustitución a tiempo.

Un ejemplo cotidiano de este mantenimiento sería la ITV, mientras que un ejemplo aplicado a un motor de inducción sería la lubricación periódica de los rodamientos.

5.1.3. MANTENIMIENTO PREDICTIVO.

Representa el tipo de mantenimiento más moderno cuyo origen se remonta a los años 60. La introducción de la electrónica, la aeronáutica y la aeroespacial supusieron la necesidad de técnicas sofisticadas de control de sistemas y aeronaves, recurriendo a técnicas de monitorización y propiciando así el inicio de este tipo de mantenimiento.

La diferencia con el mantenimiento preventivo es que este tipo de técnica no actúa sobre la máquina o elemento directamente, sino que antes de hacerlo, comprueba si es necesario según el estado de la misma.

El mantenimiento predictivo, por lo tanto, consiste en la monitorización de un parámetro del equipo a mantener. La variación de este parámetro refleja el estado de dicho equipo. De tal modo que, si el valor de este indica un potencial defecto del equipo se actúe sobre el mismo antes de que sea demasiado tarde y un fallo potencial se convierta en uno irreversible. Se consigue así minimizar el coste económico de posibles reparaciones y optimizar el mantenimiento al tener un control de la evolución del equipo en todo momento.

Los parámetros o variables constituirán valores de alguna magnitud física directa o transformaciones matemáticas de variables indicativas del estado del equipo o máquina. Algunos de estos parámetros pueden ser la temperatura, la vibración, la presión, el ruido, la tensión, la intensidad, etc.

La base de este tipo de mantenimiento, como se introdujo, es la monitorización de la variable elegida. Existen diferentes técnicas de monitorización, que se explicarán en el apartado 5.2.

A la hora de seleccionar los sensores empleados en la captura de la magnitud física, se busca, entre otros aspectos, los siguientes:

- Precisión, rapidez y autocorrección.
- Elevada fiabilidad.
- Sencilla calibración.
- Posibilidad de funcionamiento bajo ambientes agresivos.
- No intrusivos, es decir, que no modifiquen el sistema.

En este sentido, si se origina un fallo en los sensores ha de detectarse rápidamente, sabiendo diferenciar un fallo en los mismos de un fallo en el equipo de estudio.

En cuanto a las técnicas de monitorización, deben poder distinguir los diferentes tipos de fallos, aunque estos se presenten de igual forma. Estas técnicas pueden desarrollarse de manera continua o discreta, es decir, controlar el valor del parámetro en todo momento o hacerlo de manera periódica.

El análisis discreto presenta el riesgo de la aparición de averías durante el tiempo en el que no se controla la variable, siendo crucial conocer la evolución de la misma y establecer en consecuencia una periodicidad eficaz de monitoreo.

Las ventajas de aplicar un mantenimiento predictivo son las siguientes:

- Al saber en qué momento exacto actuar sobre la máquina se eliminan tiempos de parada y desmontajes evitables.
- Como ya se dijo, la detección temprana de averías evita consecuencias mayores, como la pérdida de producción o la destrucción de la máquina.
- Aumenta la fiabilidad de la instalación al controlar los equipos que la forman.
- Una precisa planificación de recursos humanos y materiales es posible gracias al control constante del estado de las máquinas, siendo innecesarios una gran cantidad de repuestos. Se decrementa así el tiempo de intervención y los costes asociados al almacenamiento.
- Se evita sustituir piezas de las máquinas en buen estado, como ocurría en el mantenimiento preventivo.
- Se potencia el conocimiento del funcionamiento de las máquinas y de la instalación.
- Estas técnicas pueden llevarse a cabo a distancia, no necesariamente cerca del equipo a mantener.

Presenta, por su parte, los inconvenientes indicados a continuación:

- Es necesario una mayor formación del equipo de mantenimiento para poder realizar las tareas de monitoreo y la interpretación correcta de los datos. Evitando así averías o paradas evitables por errores humanos.
- Se precisa una elevada inversión para los equipos de medida y registro de datos y para un almacenamiento de los mismos.
- Aparición de fallos humanos como la indecisión del momento adecuado de intervención frente a ciertos valores de los parámetros.

Como se ve, el alto coste tanto de equipos de monitoreo como de operarios es el principal inconveniente del mantenimiento predictivo. Sin embargo, presenta múltiples ventajas, constituyendo el tipo de mantenimiento más sofisticado. Se aplicará en los casos siguientes:

- Cuando el coste total de implementarlo es menor al coste que acarrear los errores de otras técnicas de mantenimiento menos precisas.
- Si es justificable el incremento de la fiabilidad del sistema.
- Si la seguridad de las personas se ve comprometida.

- Cuando la avería del equipo puede ocasionar un fallo catastrófico en otros dispositivos.

5.2. TÉCNICAS DE MANTENIMIENTO PREDICTIVO EN MOTORES DE INDUCCIÓN.

La importancia de los motores de inducción en la industria, recalcada continuamente en el presente trabajo, así como el desarrollo de la propia industria, provocan la búsqueda de mayor fiabilidad en dichos motores. Siendo un fallo inesperado algo impermissible en aplicaciones complejas o de gran importancia.

El entorno de trabajo de este tipo de motores, al igual que el de otros, frecuentemente es hostil. De igual modo, están expuestos a defectos de fabricación y a un uso incorrecto. En este sentido, la aparición de fallos internos como cortocircuitos, barras rotas o averías en los rodamientos puede considerarse inevitable. Con igual carácter pueden presentarse fallos ocasionados por agentes externos al motor, así como asimetrías en la alimentación o bloqueo del rotor.

Por todo lo anterior, el mantenimiento predictivo cuenta con un papel crucial, posibilitando la detección a tiempo de potenciales fallos. Se han desarrollado de esta manera técnicas que monitorean magnitudes que se obtienen en terminales del motor o aquellas observables mediante el uso de sensores. En este sentido se pueden clasificar estas técnicas en aquellas que se desarrollan con el motor en funcionamiento y aquellas en las que el motor está fuera de servicio.

En este apartado se presentarán algunas de las muchas técnicas de mantenimiento predictivo en motores de inducción, con especial atención al análisis espectral de la corriente del estátor, siendo esta la técnica usada para la obtención de los datos empleados en el presente Trabajo Fin de Grado.

5.2.1 TÉCNICA DE DIAGNÓSTICO DE LA RESISTENCIA DE AISLAMIENTO.

Constituye un tipo de técnica para comprobar el estado del aislamiento del motor, en el que este se encuentra fuera de servicio.

Este tipo de ensayo se suele aplicar a motores de alta tensión y se realiza en los siguientes casos:

- Verificación de utilización de nuevos motores.

- Revisión tras cierta actividad de mantenimiento de motores en funcionamiento.
- Prueba tras una perturbación en la red.
- Revisión periódica del estado del motor.

Consiste en medir la resistencia de aislamiento aplicando una determinada tensión al devanado en cuestión. Se generará una corriente en el mismo y así se podrá medir la resistencia buscada.

El nivel de tensión ha de ser adecuado, de modo que no suponga un esfuerzo a mayores sobre el aislante. En este sentido, la IEEE std 43-2000 presenta las tensiones de ensayos recomendadas en función de las tensiones nominales de los motores, mostradas en la Tabla 5.1.

Tensión nominal del motor entre fases (V)	Tensión de fase de ensayo (V)
< 1000	500
1001 ÷ 2500	500 ÷ 1000
2501 ÷ 5000	2500 ÷ 5000
5001 ÷ 12000	2500 ÷ 5000
> 12000	5000 ÷ 10000

Tabla 5.1. Tensión de ensayo en función de la tensión nominal del motor [15]

Una vez determinado el nivel de tensión adecuado, este se aplica durante 1 minuto entre el devanado del motor y su masa o tierra. Transcurrido este tiempo se procede a la medición de la resistencia de aislamiento.

La tensión aplicada en el ensayo puede ser alterna o continua, sin embargo, se prefiere la continua por las razones siguientes:

- Mayor facilidad de transporte de la fuente de tensión continua, más ligera y compacta.
- Menores descargas parciales en el aislamiento durante el ensayo, siendo menor el daño al mismo.

- Las sobretensiones durante el funcionamiento del motor que puede sufrir son más semejantes empleando una fuente de continua que con una de alterna.
- Pueden darse variaciones en la corriente durante el ensayo indicativas de cierto tipo de fallo del aislamiento.
- El daño en el motor por rotura del aislamiento será menor con una fuente de corriente continua.

El resultado de este ensayo proporciona información sobre el aislamiento en relación a la contaminación superficial del mismo por humedad y suciedad. De tal manera que el valor de la resistencia del aislamiento depende de estos factores y, además, de la temperatura.

La presencia de humedad en los devanados puede suponer una disminución clara del valor de la resistencia de aislamiento, por lo que este ensayo ha de realizarse por encima de las condiciones de rocío. Por su parte, el aumento de temperatura ocasiona la disminución de la resistividad del aislante. Cada aislante presenta un cambio diferente frente al aumento de temperatura, de modo que, para poder efectuar comparaciones de diferentes ensayos, será necesario o bien hacer los mismos a igual temperatura o corregir la resistencia de aislamiento obtenida en cada caso con una resistencia base. Esta suele ser de 20°C o 40°C, consiguiendo el valor corregido de resistencia mediante la siguiente fórmula:

$$R_x = k_t R_t \quad (5.1)$$

Donde:

R_x es la resistencia corregida.

k_t es el factor de corrección de temperatura, que ha de obtenerse para cada tipo de aislamiento.

R_t es la resistencia base.

En cuanto a la interpretación de resultados, es decir, lo que indica el valor de la resistencia de aislamiento, se presenta como una tarea compleja. No existen reglas que establezcan el valor mínimo que debería presentar un motor, dependerá del tipo de motor, del estado del aislamiento, de la tensión aplicada, etc.

En esta tarea, el buen juicio de un técnico de mantenimiento con experiencia para determinar si el resultado está dentro de la normalidad o no, es habitual.

La posesión de ensayos previos o tendencias de máquinas similares facilitan dicha interpretación de resultados. En este sentido, existen estándares que establecen valores mínimos de resistencias de aislamientos bajo ciertas condiciones de ensayo, como el nivel de tensión. Estos valores mínimos serán menores para bobinas antiguas que para aquellas nuevas. Si se da el caso que el valor de la resistencia es inferior al considerado mínimo, el motor no podrá volver a ponerse en funcionamiento. Si este hecho se da en un devanado nuevo, puede ser indicativo de que el devanado esté contaminado o lleno de agua.



Figura 5.1. Ensayo de resistencia de aislamiento a un motor de tracción. [15]

ÍNDICE DE POLARIZACIÓN.

El índice de polarización se define como la relación entre la resistencia de aislamiento obtenida en un ensayo en 1 minuto con aquella obtenida a los 10 minutos una vez aplicada la tensión.

$$IP = \frac{R_{1min}}{R_{10min}} = \frac{I_{1min}}{I_{10min}} \quad (5.2)$$

Este parámetro nos indica el estado de humedad y limpieza de la máquina. En cuanto a su obtención, no será necesaria la corrección de la resistencia con la temperatura, por la poca influencia de la misma.

En el caso de tratarse de motores con modernos devanados preformados, si se obtiene un valor alto de resistencia de aislamiento no se precisará el cálculo de este parámetro.

El IP constituye un valor adimensional que nos permite, entre otras cosas, conocer que, si se obtiene un valor IP demasiado alto en un devanado del estátor, es probable que el devanado esté envejecido térmicamente. Si obtenemos por el contrario un valor por debajo del mínimo establecido en un devanado nuevo, es posible, al igual que con la resistencia de aislamiento, que esté contaminado o lleno de agua.

Por último, existen indicaciones cualitativas del estado del devanado, como las presentes en la tabla 5.2.

Estado del aislamiento	Índice de polarización
Mal estado	$IP < 1$
Cuestionable	$1 \leq IP < 2$
Bueno	$2 \leq IP < 4$
Muy bueno	$4 \leq IP$

Tabla 5.2. Estado del aislamiento en función del valor del IP. [15]

Para concluir el apartado 5.2.1, a continuación, se muestran algunos inconvenientes del método de obtención de la resistencia de aislamiento.

- Los devanados sufren estrés, pudiendo ocasionar su ruptura.
- Es necesaria la interpretación de resultados por un técnico con experiencia.
- Fallos tales como fisuras no son detectados si no presentan humedad o suciedad.
- No se obtienen defectos relacionados con la rotación del motor, al tener que estar este parado.

5.2.2. ENSAYO DE ONDA DE CHOQUE.

Constituye otro tipo de análisis del aislamiento del motor realizado mientras el mismo está fuera de servicio. Se emplea para determinar el estado del aislamiento entre espiras. Este aspecto no es detectado por técnicas como la

anterior, dirigidas a mostrar el estado del aislamiento respecto a masa, como se vio.

La metodología de este ensayo consiste en aplicar pulsos de tensión sobre los dos devanados bajo estudio. Estos impulsos, del orden de $0.2 \mu s$ de tiempo de subida y de amplitud variable, son generados por un generador de ondas de choque a través de la descarga de un conjunto de condensadores.

El patrón de onda resultante de aplicar estos pulsos a un devanado es propio de la inductancia de dicho devanado y del condensador del generador de ondas. Pudiendo guardarse para comprobar la evolución del motor o para compararlo con otros iguales.

De este modo, asumiendo que las fases de los devanados son idénticas, frente a los impulsos de tensión antes comentados deberán generar patrones de onda iguales, superponiéndose ambos.

En caso de que alguno de los devanados presente algún fallo, como un cortocircuito, los patrones de onda serán distintos, como se puede observar en la figura 5.2.

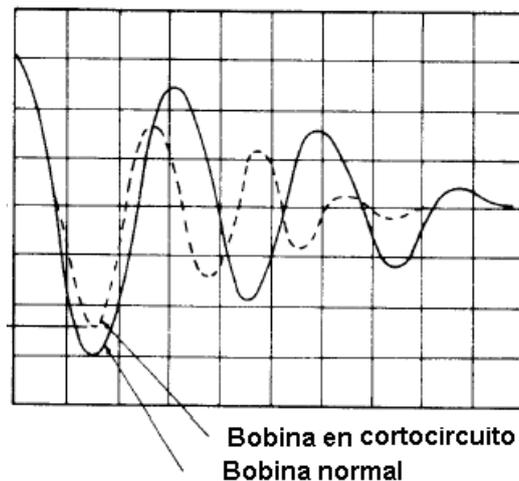


Figura 5.2. Patrones de ondas resultantes del ensayo de ondas de choque. [19]

El resultado del ensayo, como se ha visto, no es numérico, sino una gráfica a interpretar. A través de la misma se pueden detectar fallos como cortocircuitos entre espiras, entre bobinas o entre fases, pudiendo derivar en fallos a tierra.

El análisis de las tres fases del devanado del motor de inducción se realiza comparándolas entre sí en parejas, estableciendo de este modo que el devanado está en buen estado en el caso de que todos los patrones de ondas coincidan.

5.2.3. MÉTODOS DE ANÁLISIS DEL NÚCLEO MAGNÉTICO.

El aumento de la necesidad de monitorización del estado del núcleo magnético se debe a la mayor eficiencia de los paquetes magnéticos y a la influencia en el resto de elementos, en cuanto a la producción y transmisión de defectos.

Para la detección de cortocircuitos entre chapas del núcleo existen principalmente dos métodos, el Método de puntos calientes y el método conocido como “EL CID”, ambos con el motor en reposo.

MÉTODO DE PUNTOS CALIENTES.

Representa el método más común para este tipo de análisis. Consiste en calentar el núcleo al excitar al motor entre el 80% y el 100% de su flujo nominal. A continuación, empleando una cámara termográfica o un termómetro láser se observan las diferentes zonas del núcleo. De esta manera, en aquellas en las que exista un cortocircuito la temperatura será mayor y, por lo tanto, será detectable a través de las herramientas anteriores.

Hay que tener presente que, si el cortocircuito no se origina en las chapas de la superficie, el calor tardará en llegar a esta. Por lo tanto, el ensayo descrito se desarrollará durante el tiempo necesario.

Este ensayo supone un elevado consumo, ya que es necesario alcanzar condiciones casi nominales. Además, presenta un riesgo para el motor al alcanzar esta una elevada temperatura sin tener el sistema de refrigeración en funcionamiento. Y, por último, requiere ciertas normas de seguridad por los valores elevados de temperatura, corriente y tensión presentes.

ELECTROMAGNETIC CORE IMPERFECTION DETECTOR (CID).

Este método se emplea para evitar los problemas descritos del método anterior, estando dirigido al análisis de grandes máquinas.

Para su ejecución es necesario desacoplar el rotor del motor. El estátor es excitado al 4% de su flujo nominal. De este modo, frente a un cortocircuito entre espiras, las corrientes parásitas o de Foucault aumentarán. Los campos magnéticos creados por dichas corrientes serán detectados mediante el paso de la bobina Chattock a través de los dientes del núcleo, consiguiendo observar así los fallos indicados.



Figura 5.3. Realización del ensayo "CID" al estátor de un motor. [19]

5.2.4. ESTUDIO DEL CIRCUITO DEL MOTOR.

Este ensayo, denominado también Motor Circuit Evaluation (MCE), es aplicado a motores de inducción trifásicos y otros motores de corriente alterna, estando estos en reposo.

Consiste en determinar los valores de las resistencias e inductancias en las tres fases del motor, estudiando además la evolución y el posible desequilibrio de las mismas. Para ello se emplean equipos que incluyen fuentes de alimentación en alterna y en continua, con baja corriente y tensión de modo que no se dañe el motor, con sistemas de adquisición y almacenamiento de datos y presentación por pantalla. Dichas medidas han de ser precisas, del orden de miliohmios y milihenrios respectivamente.

Respecto a la resistencia de las fases, se realiza la medida en cada una de las tres y se comparan los valores con los iniciales que presentaba el motor. Pudiendo establecer así si existen desequilibrios en este sentido, por ejemplo, por una mala conexión de una de las fases en los bornes del motor.

En cuanto a la medida de la inductancia, esta nos da una idea del estado del rotor y el estátor, ya que constituye una combinación de la inductancia propia y mutua de los devanados. Un desequilibrio entre inductancias en las fases da lugar a un desequilibrio de las corrientes que por estas circulan, causando así calentamientos, disminución del par motor, entre otros. Además, en el caso de que se origine un cortocircuito entre espiras del estátor, la inductancia de la fase en cuestión disminuirá. Esto se debe a que dicha inductancia es proporcional al cuadrado de las espiras.

5.2.5. TERMOGRAFÍA

El análisis de la temperatura de las partes del motor constituye un método desarrollado mientras el motor se encuentra en funcionamiento.

Mediante sondas de temperatura se observa el calentamiento de las diferentes zonas del motor. Esto nos permite detectar diferentes tipos de fallos, como pueden ser los asociados al núcleo magnético, expuestos en el apartado 5.2.3.

Este método presenta limitaciones como el análisis del interior del motor. Sin embargo, es útil para detectar averías en los siguientes elementos:

- Rodamientos.
- Conexiones eléctricas.
- Contactos entre las barras y el anillo de cortocircuito.
- Puntos calientes que se propagan a la superficie.

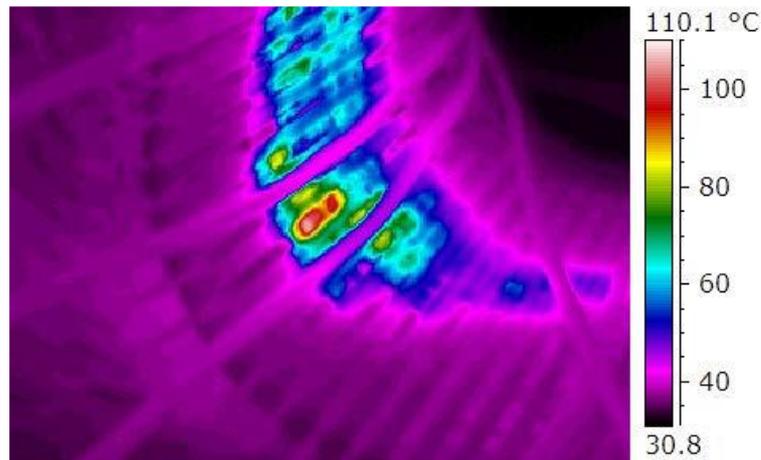


Figura 5.4. Punto caliente en el estator de un motor detectado mediante termografía. [19]

5.2.6. ANÁLISIS DE VIBRACIONES.

El análisis de vibraciones de un motor de inducción es otra técnica de mantenimiento predictivo con el motor en funcionamiento. Igual carácter presentan el análisis de la corriente de alimentación del estator y el estudio del flujo axial de dispersión, tratados en posteriores apartados. Todos estos presentan procedimientos semejantes, diferenciándose en el tipo de sensor empleado. Dichos sensores son un acelerómetro en el caso del análisis de vibraciones, una bobina para la medida del flujo y una pinza amperimétrica en el caso del análisis de la corriente.

El análisis de vibraciones en un motor de inducción, teniendo en cuenta que la vibración es algo normal, sirve para establecer el nivel de calidad que presenta la máquina en cuanto a su construcción, montaje y funcionamiento. Además, será indicativo de potenciales averías en la misma.

En el sentido anterior, se pueden desarrollar dos técnicas, el análisis espectral de la señal de vibración y el estudio del nivel global de vibración. Este último,

de ejecución sencilla, refleja el estado del motor y de su montaje. Además, refleja la posible presencia de averías al aumentar el nivel de vibración, pero sin indicar su naturaleza. En cuanto a la otra técnica, mediante el acelerómetro se recoge el espectro de vibración del motor donde la presencia de armónicos es indicativa de averías en el mismo.

Entre otros, el uso del análisis de vibraciones se emplea para la detección de barras rotas en motores de jaula de ardilla y para el diagnóstico del estado de los rodamientos.

DETECCIÓN DE BARRAS ROTAS EN UN MOTOR DE JAULA DE ARDILLA.

Al producirse la rotura o el agrietamiento de una barra del rotor o del anillo de cortocircuito se origina una discontinuidad en las corrientes que circulaban por dicha barra y por las vecinas. El campo del entrehierro se ve alterado, aumentando su contenido en armónicos, interaccionando estos con las corrientes del rotor y dando lugar a fuerzas que a su vez provocan vibraciones en el motor de diferentes frecuencias.

Estas averías se manifiestan en el espectro de vibraciones del motor mediante diferentes formas, siendo una de ellas la aparición de bandas laterales de la frecuencia de giro del motor a una distancia de dos veces la frecuencia de deslizamiento, del siguiente modo:

$$f_{brv} = f_r \pm 2sf_1 \quad (5.3)$$

Donde:

f_r es la frecuencia de giro del motor.

f_1 es la frecuencia de alimentación del motor.

s es el deslizamiento.

En la Figura 5.5 se puede observar el espectro de vibración de un motor sano (a) y el espectro de vibración de un motor con una barra rota (b), apreciando la diferencia de amplitud de las componentes de frecuencia indicativas de fallo.

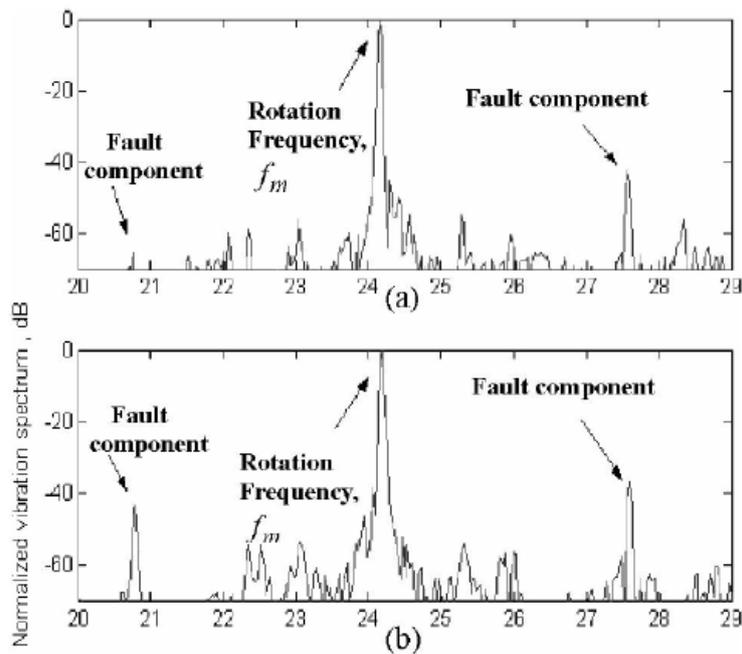


Figura 5.5. Espectro de vibración de un motor sano y uno con una barra rota. [19]

El uso de este método para la detección de este tipo de fallos no ha sido muy eficaz debido al condicionamiento de las propiedades dinámicas del motor y de su estructura. Además, se encuentra eclipsada por el análisis de la corriente de alimentación del estátor, mucho más precisa frente a estos fallos.

DIAGNÓSTICO DEL ESTADO DE LOS RODAMIENTOS.

Al igual que en caso anterior, el defecto en estos elementos puede detectarse en el espectro de vibraciones de los mismos. La presencia de ciertas frecuencias es indicativa de averías en las diferentes partes del rodamiento. Estas frecuencias, según sus siglas en inglés, son las siguientes

- BPF (Ball Pass Frequency Inner Race): Frecuencia de paso de las bolas por la pista interior. Es el número de elementos rodantes que pasan por cierto punto de la pista interior en cada giro del eje.
- BPO (Ball Pass Frequency Outer Race): Frecuencia de paso de las bolas por la pista exterior. Será el número de veces que un elemento rodante pase por un punto de la pista exterior cada vuelta del eje.
- FTF (Fundamental Train Frequency): Frecuencia fundamental que indica el deterioro de la jaula del rodamiento. Es el número de giros que realiza la jaula por giro del rodamiento.

- BSF (Ball Spin Frequency): Frecuencia de rotación de los elementos rodantes. Constituye el número de vueltas de estos elementos por cada giro del eje.

Mediante las ecuaciones siguientes, se obtienen los valores de las anteriores frecuencias:

$$\text{BPFI} = \frac{N_b}{2} (1 + A)n \quad (5.4)$$

$$\text{BPFO} = \frac{N_b}{2} (1 - A)n \quad (5.5)$$

$$\text{FTF} = \frac{P_b}{2B_d} (1 - A)^2 n \quad (5.6)$$

$$\text{BSF} = \frac{1}{2} (1 - A)n \quad (5.7)$$

Representando las variables anteriores, mostradas algunas en la Figura 5.6, lo siguiente:

N_b es el número de bolas o de rodillos.

B_d es el diámetro de la bola o rodillo.

P_b es el diámetro de una circunferencia imaginaria que pasa por el centro de los elementos rodantes.

$$A = \frac{B_d}{P_b} \cos\alpha$$

α es el ángulo de contacto.

n es el número de revoluciones del eje.

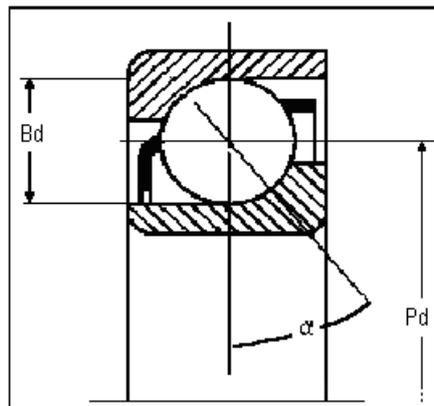


Figura 5.6. Valores para el cálculo de frecuencias de fallo en rodamientos. [15]

Hoy en día los propios fabricantes de rodamientos proporcionan los valores de frecuencias calculadas mediante las fórmulas anteriores. Existiendo además bases de datos que recogen estos valores para una gran variedad de rodamientos.

En la Figura 5.7 se puede observar el espectro de vibraciones de un rodamiento sano (caso a), el de un fallo en las bolas (caso b), el de un fallo en la pista interior (c) y, por último, el correspondiente a un defecto en la pista exterior (d).

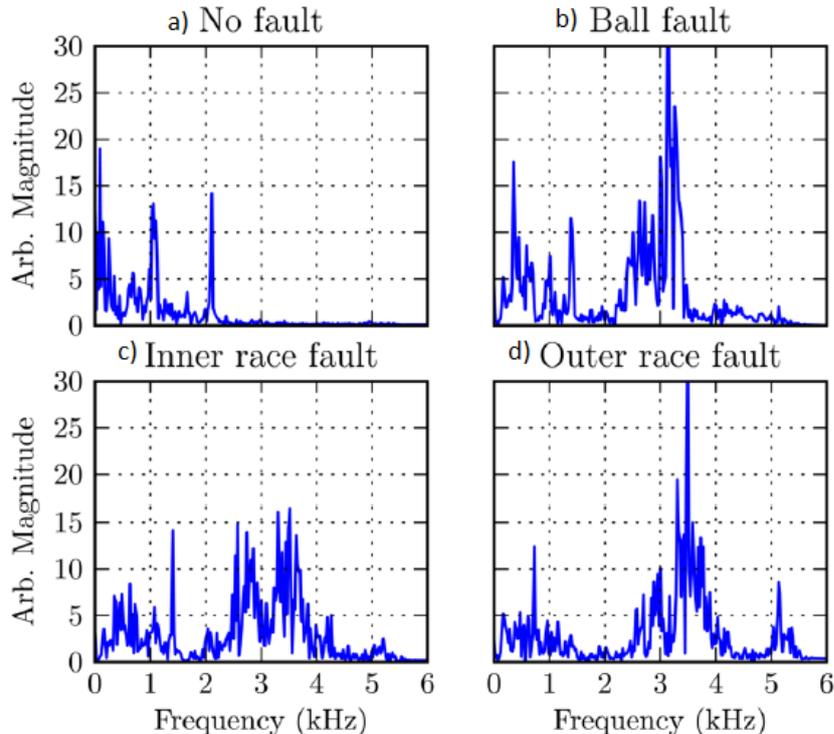


Figura 5.7. Espectro de vibración de un rodamiento para diferentes fallos. [19]

5.2.7. ESTUDIO DEL FLUJO AXIAL DE DISPERSIÓN.

El flujo axial de dispersión aparece en los motores como consecuencia de las asimetrías de los circuitos eléctricos y magnéticos. La causa de estas pueden ser las tolerancias de fabricación, la presencia de imperfecciones de la geometría del aislamiento o la falta de homogeneidad de los materiales empleados.

El flujo radial, por su parte, es el que transmite el trabajo útil al rotor, suponiendo, por lo tanto, una serie de pérdidas en la transmisión de trabajo la aparición del flujo axial.

El flujo axial total que existe en el entrehierro es consecuencia de las corrientes que circulan por el estátor y el rotor. De modo que el contenido armónico del mismo irá relacionado con el de las corrientes de dichas partes del motor.

La presencia de un fallo en estátor o rotor provocará una alteración armónica en las corrientes de los mismos, que se traducirá en una alteración del flujo axial de dispersión. Hay que tener en cuenta que las diferentes asimetrías introducen armónicos, cuya frecuencia se precisa conocer para ser diferenciadas de los posibles fallos.

La medida del flujo axial se realizará mediante un sensor sencillo. Se trata de una bobina, como la mostrada en la Figura 5.8, colocada en el lateral del motor. Dicha bobina recoge el espectro de flujo axial de dispersión, pudiendo identificar así cada tipo de fallo en el motor a través de la presencia de armónicos característicos de los mismos.



Figura 5.8. Bobina para la medida del flujo axial de dispersión [15]

La técnica de mantenimiento predictivo presente, se emplea en la detección de barras rotas en el rotor, desequilibrio entre fases, excentricidad, bobinado en cortocircuito, etc., presentando una especial importancia para la detección de este último tipo de problema. Si los cortocircuitos entre espiras se analizan mediante el método de ondas de choque, se necesita que el motor esté fuera de funcionamiento, además de requerir un tiempo elevado, como se vio. Sin embargo, con el análisis del flujo axial de dispersión esto ya no es necesario.

La degradación del aislamiento en numerosas ocasiones se inicia por cortocircuitos entre espiras, pudiendo ocasionarse defectos a masa. Esto justifica la importancia de la mejora de su detección mediante la metodología descrita en este apartado, presentando estos fallos, para ello, una frecuencia característica identificable en el espectro.

Por último, en cuanto a la interpretación de resultados, consiste en una tarea compleja que requiere personal cualificado.

5.2.8. ANÁLISIS ESPECTRAL DE LA CORRIENTE.

La detección de averías en un motor de inducción mediante el Análisis Espectral de la Corriente o MCSA (Motor Current Signature Analysis), se fundamenta en el análisis de los diferentes componentes de frecuencia presentes en el espectro de la corriente del estátor.

Esta técnica se emplea en la detección de los siguientes fallos del motor:

- Asimetrías en la jaula, ocasionadas por barras rotas o agrietadas, grietas en el anillo de cortocircuito o fisuras en la unión de las barras y el anillo.
- Excentricidad dinámica y estática.
- Defectos en los rodamientos.

Los fallos anteriores introducen corrientes al estátor con frecuencias características en forma de bandas laterales, pudiendo así ser detectados en el espectro de la corriente del estátor. Estas bandas laterales aparecerán alrededor de la frecuencia fundamental de la corriente de alimentación y, además, en otros armónicos de orden superior.

La amplitud de las anteriores componentes de frecuencia estará relacionada con la gravedad de cada tipo de fallo. De manera general, dicha amplitud es mayor a medida que se incremente la severidad del fallo, aunque este crecimiento no es lineal.

A continuación, se tratará la detección de cada uno de los fallos enumerados anteriormente mediante el Método del Análisis Espectral de la Corriente. Se indicará, en cada caso, la ecuación que posibilita conocer la frecuencia de la corriente donde se puede localizar cada uno de los mismos.

DETECCIÓN DE ASIMETRÍAS EN LA JAULA.

Frente a este tipo de fallo, el método con mayor fiabilidad es el tratado en el presente apartado.

Cuando se origina una rotura de una barra de la jaula del motor, se desequilibra el reparto de corrientes en el rotor. Esto se debe a que el resto de barras han de asumir la corriente que la rota no puede transportar. La consecuencia es una alteración del campo magnético en el rotor, apareciendo flujos armónicos e induciendo corrientes armónicas en el bobinado del estátor.

La frecuencia característica para este tipo de fallo se obtiene mediante la siguiente fórmula:

$$f = (1 \pm 2 n s) \quad (5.8)$$

Siendo:

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

f_1 es la frecuencia de alimentación del motor.

s es el deslizamiento.

El espectro de la corriente del estátor de un motor de inducción con jaula presenta un valor dominante correspondiente a la frecuencia de alimentación. A cada lado del mismo se encuentran valores equidistantes, cuyas frecuencias se obtiene con la Fórmula 5.8. La amplitud de los mismos y su relación con la gravedad del fallo, será un tema a tener en cuenta. Para establecer esta relación existen diversos métodos, de los que se puede destacar el uso de tablas de diagnóstico.

El empleo de tablas de diagnóstico para determinar la importancia de un fallo en la jaula del motor representa el método más extendido. Su metodología consiste en medir la diferencia de amplitudes, en decibelios, entre el valor de la componente fundamental y la banda lateral inferior, como se muestra en la Figura 5.9.

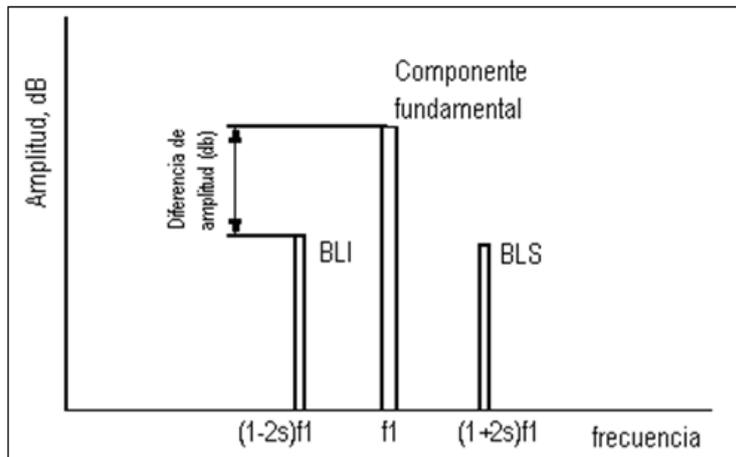


Figura 5.9. Diferencia de amplitud entre la componente fundamental de la corriente del estátor y la banda lateral inferior (BLI) [15]

El valor obtenido en la anterior operación indicará, comparándolo con los valores recogidos en las tablas de diagnóstico, el estado buscado de la jaula. La Tabla 5.3 muestra un ejemplo de este tipo de tablas, con diagnósticos de diferentes autores, en la que observamos que las diferencias entre estos son pocas.

dB (*)	Fernández - Univ. Oviedo	Nicholas	EASA
Límite superior			
60	Motor sano	Excelente	Buen estado
54		Buena	
49	Algún punto de alta resistencia	Moderada	Condición marginal
48			
46	Varios puntos de alta resistencia	Barras rotas o superficies de alta resistencia	Al menos una barra rota
45			
44	Muchos puntos de alta resistencia o una barra rota	Múltiples superficies de alta resistencia	Más de una barra rota
42			
40	Al menos una barra rota	Múltiples barras rotas	Daño severo
39			
36	Varias barras rotas		
35			
30			
Condiciones de carga	> 70% Carga	>75% Carga	>50% Carga

Tabla 5.3. Tabla de diagnóstico del motor en función de la diferencia de amplitudes entre la fundamental y la BLI [15]

En el sentido anterior y tal como refleja la Tabla 5.3, bajo un funcionamiento normal del motor, el valor de la amplitud de la banda lateral inferior se situará entre 50 y 60 dB por debajo de la amplitud de la frecuencia de la red. La disminución de esta distancia, por lo tanto, será indicativo de la presencia de asimetrías en el rotor.

En la Figura 5.10 se puede observar la amplitud elevada de la banda lateral inferior de la componente fundamental de frecuencia, reflejando problemas de asimetrías en el rotor del motor.

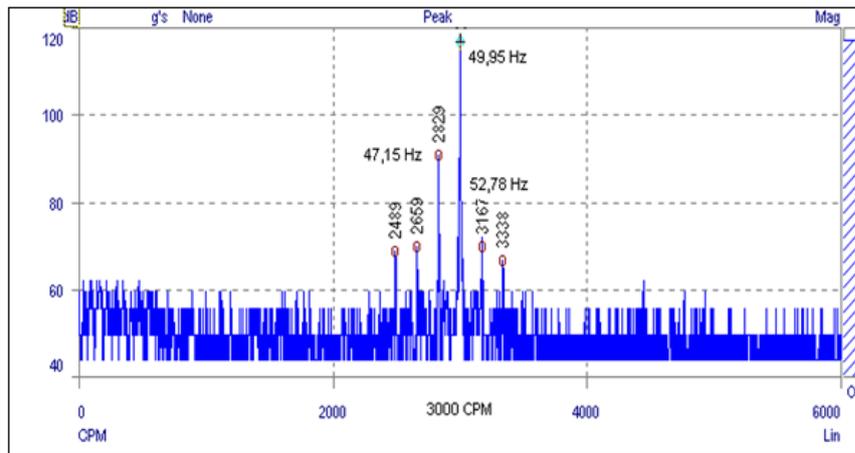


Figura 5.10. Espectro de corriente del estátor de un motor con asimetría del rotor [15]

DIAGNÓSTICO DE EXCENTRICIDADES.

La excentricidad entre estátor y rotor es algo presente en todos los motores de inducción. Sin embargo, la aparición de un determinado nivel de esta provoca la creación de nuevos armónicos en el campo del entrehierro y también el posible aumento de los armónicos ya existentes.

La ecuación general que permite detectar este tipo de problemas en el espectro de corriente, indicando su frecuencia característica, es la siguiente:

$$f_{exc} = f_1 \left[(R \pm n_d) \frac{1-s}{p} \pm 1 \right] \quad (5.9)$$

Donde:

f_1 es la frecuencia de alimentación.

R es el número de ranuras del rotor.

n_d es el orden de excentricidad, pudiendo ser:

$n_d = 0$ en el caso de excentricidad estática.
 $n_d = 1$ para excentricidad dinámica.

s es el deslizamiento del motor.

p es el número de pares de polos del motor.

De este modo, para el caso de excentricidad estática la fórmula anterior presenta la forma mostrada a continuación. Coincidirá con la fórmula que indica el valor de frecuencia del armónico principal de ranura, debiéndose este a la propia construcción del estátor. Esto supone que este tipo de excentricidad no introduzca nuevos armónicos de la corriente, sino que aumente la amplitud del armónico principal de ranura.

$$f_{exc} = f_1 \left[R \frac{1-s}{p} \pm 1 \right] \quad (5.10)$$

En cuanto a la excentricidad dinámica, la fórmula quedará como se muestra a continuación.

$$f_{exc} = f_1 \left[(R \pm 1) \frac{1-s}{p} \pm 1 \right] \quad (5.11)$$

Las ecuaciones anteriores proporcionan valores de frecuencia alejados de aquellos indicativos de fallos en el rotor, por lo tanto, será una ventaja a la hora de no originar confusión en el diagnóstico de fallos.

Para la detección de excentricidad mixta, es decir, excentricidad dinámica más excentricidad estática, debida a la construcción del motor o bien, presente por un fallo en el mismo, existe la siguiente fórmula, indicando la frecuencia característica en el caso de que se dé este tipo de fallo.

$$f_{exc} = f_1 \pm n f_r \quad (5.12)$$

Siendo:

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

f_1 la frecuencia de alimentación.

f_r la frecuencia de giro del rotor.

DETECCIÓN DE AVERÍAS EN LOS RODAMIENTOS.

La presencia de fallos en los rodamientos como el desgaste, un incorrecto montaje o problemas en los elementos rodantes, es decir, en las bolas o rodillos, pueden provocar excentricidad en el motor. Esto supone una alteración de la distribución de flujo en el entrehierro, originando la aparición de corrientes armónicas en el estátor. Las frecuencias de estas corrientes, podrán identificarse mediante la siguiente fórmula.

$$f_{\text{rod}} = |f_1 \pm n f_v| \quad (5.12)$$

Donde:

f_1 es la frecuencia de alimentación.

f_v corresponde a las frecuencias característica de vibración, BPF1, BPF0, FTF y BST, recogidas en el apartado 5.2.6.

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

VENTAJAS DEL ANÁLISIS ESPECTRAL DE LA CORRIENTE.

La principal ventaja que presenta este método frente a otros similares ya tratados, como son el análisis de vibraciones y el análisis del flujo de dispersión, es el sensor empleado. En el caso de los acelerómetros, requieren una colocación estratégica para una buena medida de las vibraciones, además de necesitar calibraciones de manera frecuente. Respecto a las bobinas empleadas para detectar el flujo magnético, se deben montar siempre en la misma posición. Frente a estos inconvenientes, la pinza amperimétrica es precisa, robusta y se puede colocar en cualquiera de las tres fases de alimentación, pudiendo estar lejos del motor.

5.2.9. ANÁLISIS MULTIPARÁMETRO.

Es necesario tener presente que en ocasiones será necesario emplear a la vez más de una de las técnicas de mantenimiento predictivo para realizar un diagnóstico al motor. Esto se conoce como “análisis multiparámetro” y es útil frente a diferentes averías que se manifiestan de igual modo. Superponiendo los resultados de los distintos métodos se consigue distinguir las causas del fallo en cada caso.

5.2.10. MCSA PARA UN MOTOR ALIMENTADO MEDIANTE CONVERTIDOR DE FRECUENCIA.

La velocidad de giro de un motor de inducción, como se vio en el Capítulo 3, está relacionada con la frecuencia de la onda de alimentación del mismo. De este modo, modificando dicha frecuencia se conseguirá variar la velocidad del motor en función de las necesidades y así conseguir, entre otras ventajas, una mayor eficiencia energética.

El convertidor de frecuencia, a través de sus tres partes, un rectificador, un filtro y un inversor, consigue variar la frecuencia de la onda que le llega al motor, controlando de este modo su velocidad. Dicha onda no va a ser senoidal perfecta, sino que estará formada, de manera general, por pulsos rectangulares de anchura y amplitud diferentes. Esta alimentación presentará, por lo tanto, un alto contenido de armónicos cuyo número, frecuencia y amplitud irán en función de la conmutación realizada por los semiconductores del convertidor de frecuencia.

La configuración de un motor de inducción junto a un convertidor de frecuencia está presente en multitud de aplicaciones como en ventiladores, bombas, compresores, máquinas elevadoras, vehículos eléctricos, etc. Se trata de un ámbito en continua expansión y mejora, con ventajas tecnológicas importantes. Sin embargo, la presencia de ondas de tensión y corrientes no senoidales introducen, como se ha comentado anteriormente, una serie de nuevos armónicos que originan la aparición de problemas en el motor, de entre los que se encuentran los nombrados a continuación:

- El paso de corriente por los rodamientos debido a las mayores tensiones inducidas en el eje.
- Aumento de pérdidas en los devanados del estátor, en el rotor y en el hierro.
- Incremento del ruido y las vibraciones.
- Mayores esfuerzos eléctricos sobre los aislamientos, potenciando su degradación.
- Disminución del par motor.

La presencia de nuevos armónicos supone una alteración en las técnicas de detección de fallos mediante el análisis espectral de la corriente del estátor. En los casos en los que la alimentación del motor se realice a velocidad constante y mediante una onda sinusoidal, el estudio del espectro de la corriente, como se ha expuesto en el presente capítulo, se limita prácticamente a la componente fundamental y sus bandas laterales. La presencia del convertidor de frecuencia y la alteración de la onda sinusoidal que conlleva, provoca la

ampliación de la banda donde se observan los fallos del motor. De esta manera, se ha de tener en cuenta dos tipos de armónicos frente a un análisis de la corriente:

- Armónicos múltiplos enteros de la frecuencia de alimentación, también conocidos como síncronos.
- Armónicos múltiplos no enteros de la frecuencia de alimentación, también denominados no síncronos, reflejando el estado del motor.

Como ya se ha indicado, los fallos en las diferentes partes del motor se manifestarán a través de determinados valores de frecuencias en el espectro de la corriente. Dichas frecuencias, en este caso, se obtienen mediante una serie de fórmulas diferentes que en el caso del motor alimentado directamente de red.

En los siguientes apartados se muestran las fórmulas empleadas para la detección de fallos en el motor de inducción alimentado mediante un convertidor de frecuencia.

DETECCIÓN DE ASIMETRÍAS EN LA JAULA.

La aparición de grietas en las barras del rotor o en el anillo de cortocircuito, así como la ruptura de estos, se manifiesta en el espectro de la corriente de alimentación del estátor mediante un valor de frecuencia obtenido con la siguiente fórmula:

$$f_{b,conv} = f_1(k \pm 2ns) \quad (5.13)$$

Donde:

f_1 es la frecuencia de la corriente de alimentación.

$n = 0, 1, 2, \dots$

s es el deslizamiento.

k es el orden de los armónicos temporales de la corriente del estátor. Depende de la estrategia de conmutación, PWM, seis escalones, etc. Para una alimentación sinusoidal, $k=1$, para un tipo PWM, los principales armónicos espaciales coinciden en orden con los temporales y para una alimentación de seis escalones, $k= 5,7,9, \dots$

DIAGNÓSTICO DE EXCENTRICIDADES.

Frente a la presencia de ambos tipos de excentricidades en el motor, las frecuencias a identificar en el espectro de la corriente serán las siguientes:

$$f_{\text{exc,conv}} = f_1 \left[k \pm n \frac{(1-s)}{p} \right] \quad (5.14)$$

Siendo:

f_1 la frecuencia de la corriente de alimentación.

$n = 0, 1, 2, \dots$

s es el deslizamiento.

k es el orden de los armónicos temporales de la corriente del estátor.

p es el número de pares de polos del motor.

DETECCIÓN DE AVERÍAS EN LOS RODAMIENTOS

En estos casos, la frecuencia que permite detectar fallos en los rodamientos en el espectro de la corriente serán las siguientes:

$$f_{\text{rod}} = f_1 \left[k \pm nq \frac{(1-s)}{p} \right] \quad (5.14)$$

Donde:

f_1 la frecuencia de la corriente de alimentación.

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

s es el deslizamiento.

k es el orden de los armónicos temporales de la corriente del estátor.

p es el número de pares de polos del motor.

q es un parámetro cuyo valor depende de la frecuencia de vibración característica del rodamiento (BPFI, BPFO, FTF y BSF) y, por lo tanto, del tipo de fallo que esté presente.

CAPÍTULO 6.

MACHINE LEARNING.

6.1 INTRODUCCIÓN

Machine Learning constituye una rama de la inteligencia artificial, que se fundamenta en dotar a las máquinas de cierto aprendizaje basado en la experiencia. Para ello, se emplean una serie de datos que reflejan el comportamiento de un sistema, sin necesidad de una o varias ecuaciones como base del estudio. Dichos datos son obtenidos mediante ensayos o durante el funcionamiento normal de un sistema. Los algoritmos creados mediante esta técnica, encuentran patrones entre los datos introducidos. Siendo capaces de reconocer dichos patrones en nuevos datos, correspondientes al sistema que se desea controlar. Por lo tanto, se entrena al algoritmo con información de la que se dispone en el momento, para hacer frente a situaciones futuras.

El uso de este tipo de técnica es conveniente cuando se disponga de un problema o situación de estudio con gran cantidad de información en forma de datos, pero sin una fórmula que los defina. Se emplea, por tanto, en un amplio abanico de sectores, como puede ser en el ámbito de la medicina, a la hora de detectar tumores, anomalías, etc. También se emplea en el sector financiero, para la negociación de acciones o la detección de fraude. En el sector eléctrico, también es común a la hora de predecir la demanda y los precios del mercado. De igual modo, este tipo de técnica se emplea en el mantenimiento predictivo, constituyendo la base de este Trabajo de Fin de Grado.

Hay dos tipos de técnicas que emplea Machine Learning. Aprendizaje supervisado y aprendizaje no supervisado. La diferencia principal es que en el supervisado se introducen al algoritmo datos de entrada y salida del sistema, mientras que, en el no supervisado, tan solo de entrada.

6.2 APRENDIZAJE SUPERVISADO

Como se ha mencionado anteriormente, en este tipo de técnica de Machine Learning, se emplean datos de entrada y las respuestas que el sistema da a los mismos, es decir, las salidas. El algoritmo tomando estos datos, es capaz de predecir futuros comportamientos frente a nuevos datos de entrada. Así, el algoritmo nos mostrará el futuro comportamiento del sistema de estudio.

Una aplicación a este método, en el ámbito de la medicina, sería la predicción de ataques cardíacos en un cierto tiempo. Para ello, es necesario conocer datos de antiguos pacientes, como la edad, el peso, la altura o la presión arterial. Estos datos constituyen las entradas. Además, se necesita saber si estos pacientes tuvieron ataques cardíacos y de ser así, qué tiempo ha transcurrido desde la toma de los datos hasta dicho ataque cardiaco, constituyendo las salidas. Introduciendo ambos datos al algoritmo en cuestión, se consigue entrenar al mismo. Este, bajo nuevos datos de entrada de un cliente, podrá predecir si dentro del tiempo estimado sufrirá riesgo de padecer un ataque cardíaco, comparando sus datos con los de otros pacientes.

Las principales técnicas de aprendizaje supervisado se dividen en técnicas de clasificación o regresión, dentro de las cuales existen una serie de algoritmos.

6.2.1. TÉCNICAS DE CLASIFICACIÓN.

Este tipo de técnicas se emplean para la predicción de respuestas discretas, agrupando los datos en categorías. Se emplean cuando los datos disponibles pueden clasificarse fácilmente en grupos.

Frente a un problema de clasificación, es necesario establecer si el mismo corresponde a una clasificación binaria o multiclase. Si corresponde a la primera, sus datos solo adoptarán dos estados. Por ejemplo, correcto o defectuoso. Si, por el contrario, sus datos pueden adoptar más estados, dichos datos han de ser abordados con una clasificación multiclase. Algunos algoritmos dentro de estas técnicas son:

Regresión Logística o *Logistic Regression*.

Este algoritmo agrupa una respuesta binaria entre un estado u otro. Representa una técnica sencilla, empleada con frecuencia como base para un estudio más complejo.

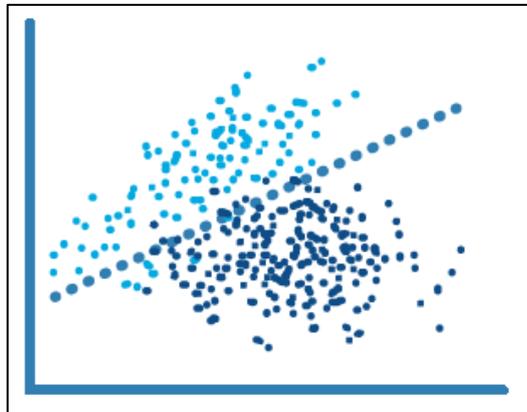


Figura 6.1. Representación del algoritmo Regresión Logística. [9]

K-Vecinos más Cercanos o *k-Nearest Neighbor (K-NN)*.

El algoritmo K-NN actúa de tal modo que, si la mayoría de los datos que se encuentren alrededor de uno en cuestión son de un estado, este será asignado con ese mismo estado. Asimismo, por tanto, que los datos cercanos son semejantes, dependiendo del número k elegido en cada caso.

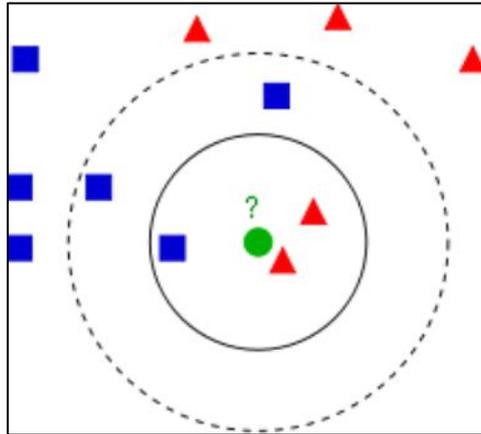


Figura 6.2. Representación del algoritmo K-NN. [6]

En la Figura 6.2, al determinar el estado del dato representado con un círculo verde, bajo la hipótesis de que $k=3$, dicho círculo será considerado como triángulo, al ser este último el más numeroso entre los tres datos más cercanos. Si, por el contrario, consideramos $K=5$, se tratará como un cuadrado, por el mismo motivo.

Máquina de Vectores de Soporte o *Support Vector Machine (SVM)*.

Este modelo separa los datos al encontrar un hiperplano que constituye la relación lineal entre entradas y salidas. Por lo tanto, se empleará cuando se trate de un problema de calificación binaria.

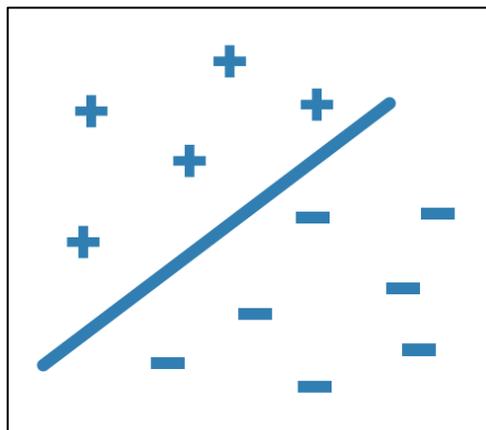


Figura 6.3. Representación del algoritmo SVM. [9]

Redes Neuronales o *Neural Network*.

Este tipo de técnica se basa en la estructura neuronal del cerebro humano. Constituyen unidades aritméticas fuertemente conectadas entre sí, capaces de abordar sistemas altamente no lineales.

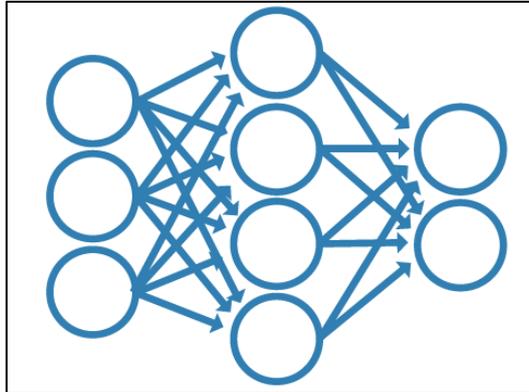


Figura 6.4. Representación del algoritmo Redes Neuronales. [9]

Árbol de decisión o *Decision Tree*.

Este algoritmo sigue una estructura similar a la de un diagrama de flujo para clasificar un conjunto de datos. Dentro del mismo, se diferencian, el nodo raíz, los nodos internos, las ramas y los nodos hoja. El primero de ellos, es el nodo superior del árbol de decisión. Los nodos internos representan una característica de los datos. Las ramas establecen una decisión o camino a la hora de clasificar ese dato y finalmente, los nodos hoja, el estado final asignado.

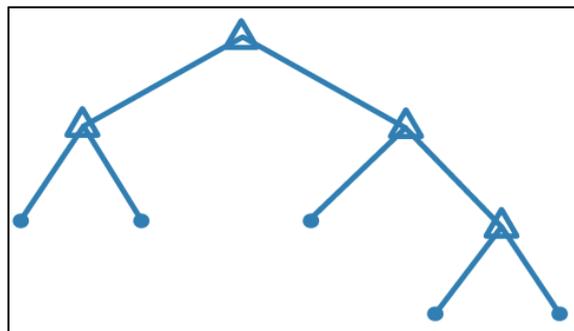


Figura 6.5. Representación del algoritmo Árbol de decisión. [9]

6.2.2. TÉCNICAS DE REGRESIÓN.

La regresión consiste en una técnica estadística en la que se relaciona una variable dependiente con un conjunto de variables independientes. El objetivo es la predicción del valor de la variable dependiente en función de los valores que adopte la independiente.

Las técnicas de regresión predicen respuestas continuas, como puede ser la variación de la demanda de electricidad. Se han de emplear cuando los datos correspondan a un número real, como el valor de la intensidad o el tiempo.

Regresión Lineal o Linear Regression.

Constituye la técnica de regresión más básica. Se emplea cuando existe una relación de linealidad entre las variables dependientes e independientes. Es decir, entre las entradas y las salidas del algoritmo. Este, mediante ecuaciones matemáticas, crea una línea recta a partir de los datos introducidos, que se ajuste en el mayor grado posible a dichos valores de entrada. Así, frente a un nuevo dato de la variable independiente, se podrá realizar la predicción del valor de la variable dependiente.

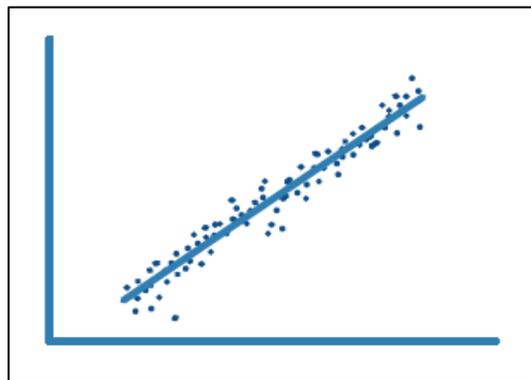


Figura 6.6. Representación del algoritmo Regresión Lineal. [9]

Regresión No Lineal o Nonlinear Regression.

Se trata, en este caso, de un algoritmo que se emplea sobre variables cuya relación sea no lineal. En este caso, el algoritmo genera una curva que mejor se adapte a los datos y que sirva para la predicción de nuevos valores de entrada.

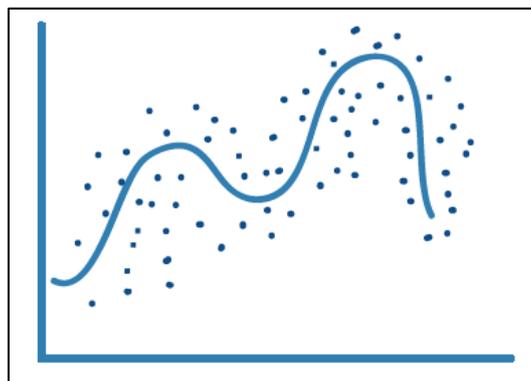


Figura 6.7. Representación del algoritmo Regresión No Lineal. [9]

SVM Regression.

Representan algoritmos cuyo funcionamiento es el mismo que los algoritmos de clasificación SVM, pero ajustados a poder predecir una variable continua. En este tipo de algoritmo, en lugar de buscar un hiperplano que separe estrictamente los datos de entrada, crea un modelo que se desvía, lo menor posible, de dichos datos, para predecir así el valor de nuevos datos de entrada.

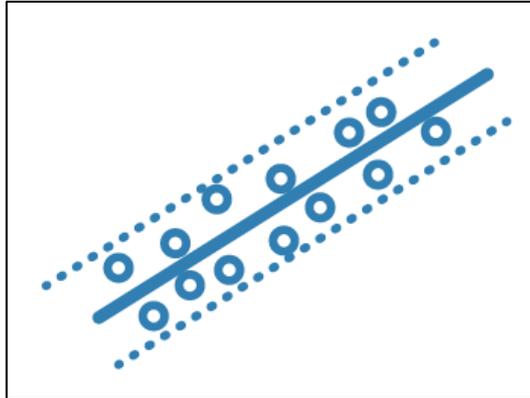


Figura 6.8. Representación del algoritmo SVM Regression. [9]

Regression Tree.

Semejante a su homónimo de clasificación, pero adaptado para poder predecir respuestas continuas.

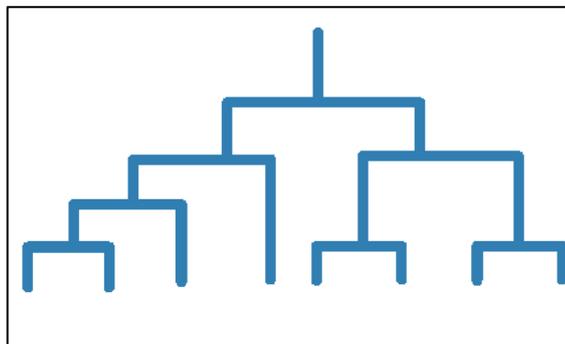


Figura 6.9. Representación del algoritmo Regression Tree. [9]

6.3 APRENDIZAJE NO SUPERVISADO.

En el aprendizaje no supervisado, como ya se indicó, tan solo se introducen los datos de entrada. El algoritmo ha de ser capaz de reconocer patrones en dichos datos y crear agrupaciones o clusters de los mismos. En este caso, el algoritmo no predice el comportamiento del sistema, ya que no contiene la respuesta a las entradas, tan solo agrupa los datos, siendo el usuario quien ha de reconocer el carácter de los mismos.

Los algoritmos de aprendizaje no supervisado se dividen en Hard clustering y Soft clustering.

6.3.1. HARD CLUSTERING: En ellos cada punto pertenece a un solo grupo. Dentro de este grupo se encuentran algoritmos como los siguientes:

K-Means.

Su funcionamiento se basa en clasificar los datos en un número 'K' de agrupaciones o clusters. Es necesario elegir de antemano dicho número de clusters. A continuación, el algoritmo fija k puntos en el conjunto de datos, formándose grupos de datos según la cercanía de cada uno a dichos valores. El siguiente paso es que los puntos anteriores se desplacen al lugar que corresponde a la media de los datos más cercanos, originando una alteración de los grupos. Dicho proceso se repite hasta que no haya más cambios. Se emplea para la agrupación rápida de gran cantidad de datos.

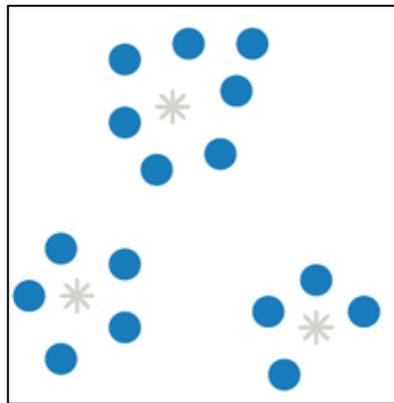


Figura 6.10. Representación del algoritmo K-Means. [9]

K-Medoids.

Representa un algoritmo similar al anterior. Pero en este, los puntos que elegía aleatoriamente el algoritmo anterior, ahora han de coincidir con algunos de los datos de entrada, estableciéndose las agrupaciones finales partiendo de dichos datos.

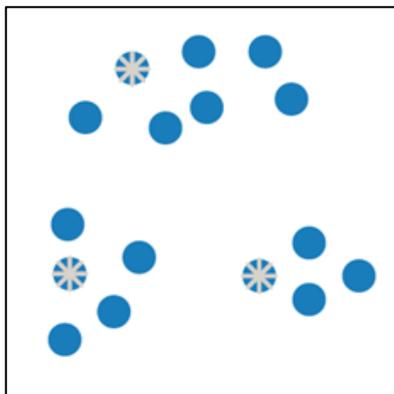


Figura 6.11. Representación del algoritmo K-Medoids. [9]

Agrupación jerárquica o Hierarchical Clustering.

Origina conjuntos unidos de pares de puntos en función de la distancia entre los mismos, siendo importante definir cómo se va a medir dicha distancia. Agrupa así los datos en un árbol binario jerárquico.

Con este algoritmo no es necesario introducir el número de agrupaciones a realizar, a diferencia de los dos anteriores.

No será adecuado para grandes conjuntos de datos. Se representa por un dendograma, como el que se muestra a continuación, donde se muestran todos los posibles clusters en los que se pueden agrupar los datos. El número más adecuado de grupos se obtendrá al trazar una horizontal por el tramo vertical más largo sin corte. En el caso siguiente, el número de agrupamientos óptimo sería dos, consiguiendo así diferenciar los datos en dos estados.

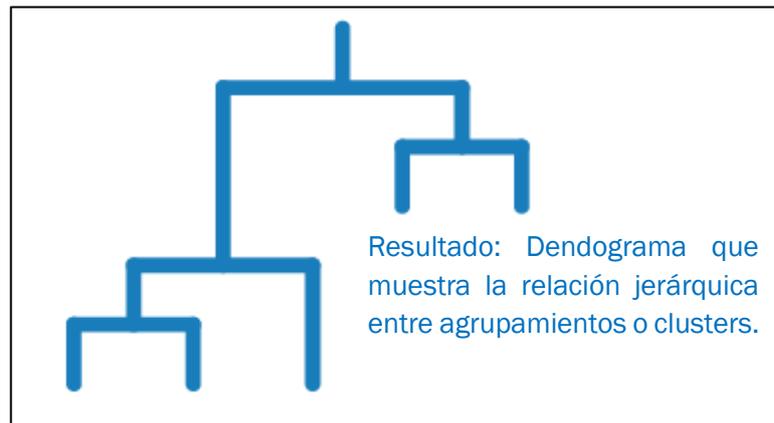


Figura 6.12. Representación del algoritmo Hierarchical Clustering. [9]

Self-Organizing Map.

Constituye un tipo de red neuronal artificial (ANN) que representa un grupo de datos en un mapa 2D, clasificado así dichos datos.

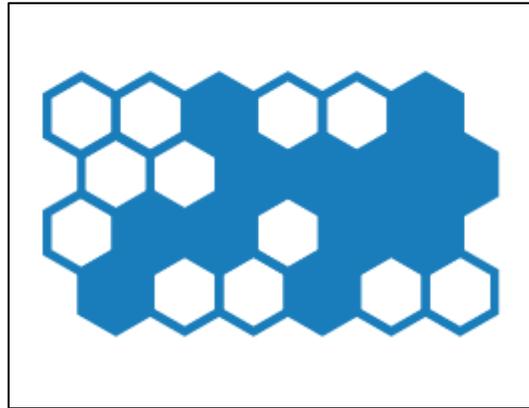


Figura 6.13. Representación del algoritmo Self-Organizing Map. [9]

6.3.2. SOFT CLUSTERING: En este grupo, un punto puede pertenecer a varias agrupaciones. Se distinguen los algoritmos siguientes:

Fuzzy c-Means.

Se emplea para la agrupación de datos cuando estos no se ajustan exactamente a un grupo y, por lo tanto, pueden pertenecer a más de un conjunto.

Es necesario conocer la cantidad de clusters en los que agrupar los datos, siguiendo una metodología similar al algoritmo K-Means, pero los datos pueden ajustarse a más de un centroide con diferente grado de pertenencia.

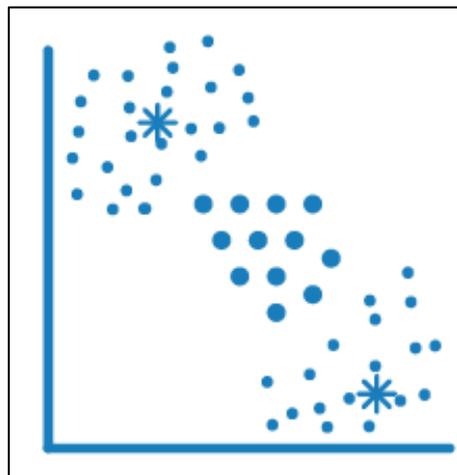


Figura 6.14. Representación del algoritmo Fuzzy c-Means. [9]

Gaussian Mixture Model.

Se utiliza a la hora de agrupar datos que proceden de diferentes distribuciones normales, indicando la probabilidad de cada dato de pertenecer a un grupo.

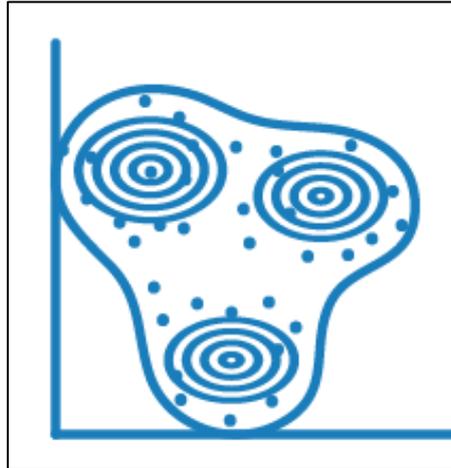


Figura 6.15. Representación del algoritmo *Gaussian Mixture Model*. [9]

CAPÍTULO 7.

OBTENCIÓN Y TRATAMIENTOS DE DATOS.

El objetivo del presente TFG, como ya se ha expuesto, es el análisis del comportamiento de técnicas de Machine Learning supervisadas y no supervisadas para el diagnóstico del estado de motores de inducción, concretamente para determinar el estado de los rodamientos de dichos motores. Para observar este comportamiento se cuenta con el estado de los rodamientos en cada momento de la recopilación de los datos. Dicho estado será necesario a la hora de trabajar con las técnicas supervisadas, entrenando a los diferentes algoritmos y, además, será útil para poder comparar la clasificación que establecen las técnicas no supervisadas a los datos introducidos con el estado real que presentan los mismos. De esta manera se conocerá la fiabilidad de ambas técnicas para la tarea expuesta, sabiendo de antemano que los resultados obtenidos con las técnicas supervisadas serán mejores, siendo estas comúnmente empleadas en este ámbito.

Se llevará a cabo el estudio de las respuestas de las técnicas anteriores frente a diferentes maneras de alimentación del motor y niveles de carga distintos.

El desarrollo de ambas técnicas, supervisadas y no supervisadas, requiere la recopilación de una serie de datos que reflejen de algún modo el estado del motor. En el presente TFG los datos representativos del estado de los rodamientos del motor se obtendrán mediante la técnica de mantenimiento predictivo Análisis Espectral de la Corriente del Estátor del Motor (MCSA). Dichos datos serán proporcionados por el Departamento de Ingeniería Eléctrica de la Universidad de Valladolid y para obtenerlos se emplearon los elementos enumerados a continuación, cuyas características se recogen en el Anexo 1.

- Un motor de inducción de Siemens.
- Dos convertidores de frecuencia, uno de la compañía WEG y otro de la compañía Allen Bradley.
- Un freno de polvo magnético para simular los diferentes niveles de carga.
- Transductores de corriente para la captura de la corriente del motor.
- Un sistema de adquisición de datos o ADS por sus siglas en inglés.

El motor de inducción se alimentó de seis maneras diferentes, mostradas a continuación:

- Directamente de la red.
- A través de un variador de frecuencia WEG.
- A través de un variador de frecuencia Allen Bradley, con condiciones de alimentación:
 - AB1: frecuencia de alimentación de 50 Hz y frecuencia de conmutación de 4 kHz.
 - AB2: frecuencia de alimentación de 25 Hz y frecuencia de conmutación de 4 kHz.
 - AB3: frecuencia de alimentación de 75 Hz y frecuencia de conmutación de 4 kHz.
 - AB4: frecuencia de alimentación de 50 Hz y frecuencia de conmutación de 5 kHz.

Además, los ensayos se realizaron a dos niveles de carga diferentes, empleando para simular dichas cargas un freno de polvo magnético.

- NC1, carga baja.
- NC2, carga nominal.

Por último, para cada uno de los casos enunciados existen cinco estados diferentes de rotura del rodamiento. Dichos estados son los mostrados a continuación:

- E0: Rodamiento sano.
- E1: Rodamiento con fallo leve.
- E2: Rodamiento con fallo moderado.
- E3: Rodamiento con fallo grave.
- E4: Rodamiento totalmente destruido.

Los diferentes grados de fallo del rodamiento se provocaron contaminando la grasa de los mismos con carburo de silicio (SiC). Como fallo incipiente se consideraron los resultados de los ensayos realizados tras dicha alteración del rodamiento. Para empeorar el estado del mismo se le hizo funcionar 12 horas seguidas en vacío, realizando los ensayos tras su enfriamiento. Dicho proceso se repitió varios días hasta que el rodamiento se bloqueó. De este modo, se ha identificado cada intervalo del procedimiento anterior con los diferentes estados que presenta el rodamiento. La Figura 7.1 muestra el rodamiento tras la finalización de las pruebas, visiblemente destrozado.



Figura 7.1. Rodamiento destrozado tras ser contaminado con SiC. [20]

De los ensayos descritos anteriormente, es decir, los resultados de las combinaciones de los diferentes tipos de alimentación, niveles de carga y estados provocados de los rodamientos, se captura la corriente del estator del motor mediante transductores. A continuación, mediante el sistema de adquisición de datos se aplica la transformada rápida de Fourier a dicha corriente, pasando así del dominio del tiempo al dominio de la frecuencia y logrando descomponer la onda no senoidal capturada en un conjunto de ondas senoidales con diferentes frecuencias y amplitudes. De este modo, el analizador ADS crea el espectro de la corriente.

El sistema de adquisición de datos recopila las diferentes frecuencias resultantes en forma de tabla, siendo estas almacenadas en formato “.mat” con el objetivo de trabajar con ellas en el sistema de cómputo numérico MATLAB, versión R2021b.

Las componentes armónicas de frecuencia de interés, recogidas en las tablas anteriores, son las correspondientes a fallos en los rodamientos. El valor de las amplitudes a analizar, por lo tanto, serán las correspondientes a las de las siguientes frecuencias del espectro de la corriente:

Motor alimentado directamente de la red:

$$f_{\text{rod}} = |f_1 \pm n f_v| \quad (7.1)$$

Motor alimentado mediante un convertidor de frecuencia.

$$f_{\text{rod,conv}} = f_1 \left[k \pm n q \frac{(1-s)}{p} \right] \quad (7.2)$$

Se presentarán, por lo tanto, las frecuencias indicativas de los diferentes tipos de fallos en función de las frecuencias características de vibración siguientes, recogidas en el apartado 5.2.7.

- BPF_I (Ball Pass Frequency Inner Race): Frecuencia de paso de las bolas por la pista interior.
- BPF_O (Ball Pass Frequency Outer Race): Frecuencia de paso de las bolas por la pista exterior.
- FTF (Fundamental Train Frequency): Frecuencia fundamental que indica el deterioro de la jaula del rodamiento.
- BSF (Ball Spin Frequency): Frecuencia de rotación de los elementos rodantes.

Las diferentes tablas creadas presentan los datos correspondientes a las frecuencias BPF_I, BPF_O, BFTF o BFS y al estado de los rodamientos. Cada una de estas tablas presentan en la primera columna el armónico en cuestión, hasta el 11 y en la segunda columna la banda alrededor de dicho armónico. El número de filas de cada tabla, por lo tanto, es de 242, al considerarse 11 armónicos y al ser el parámetro “n” de la Fórmula 7.1 y de la Fórmula 7.2 de las dimensiones siguientes, correspondientes con la banda alrededor de cada armónico.

$n = -11, -10, -9, \dots, 9, 10, 11$.

El resto de columnas de cada tabla contienen los valores de las amplitudes en decibelios (dB) de las frecuencias correspondientes a cada armónico y su banda lateral. Por lo que para obtener el valor de dichas amplitudes se realizaron varios ensayos en cada caso.

La amplitud de la componente de frecuencia característica de cierto fallo, generalmente, crece con la gravedad del mismo, pero no de manera lineal. De modo que será importante la experiencia para establecer los límites a tener en cuenta de estos valores indicativos de fallos. En este sentido, para el caso de estudio, se tiene la certeza de que las amplitudes presentes corresponden a cada tipo de estado de los rodamientos ya que dichos estados han sido provocados intencionalmente.

El siguiente paso una vez recopilados los datos es su tratamiento para poder trabajar con las herramientas empleadas en el presente Trabajo Fin de Grado. Estas herramientas están contenidas en el sistema de cómputo numérico MATLAB. Para el caso de técnicas de Machine Learning supervisadas se emplea la APP Clasification Learner, permitiendo entrenar un algoritmo en cuestión frente a futuros diagnósticos, introduciendo para ello el estado de los rodamientos. Para las técnicas no supervisadas, por su parte, se emplean

funciones dentro del entorno de MATLAB para el mismo fin, pero esta vez sin proporcionar al algoritmo el estado de los rodamientos.

Para todo lo anterior, como se adelantó, es necesario tratar los datos introduciéndolos en forma de tabla. Para ello, se emplean una serie de scripts mostrados en el Anexo 2 que trasponen y unen las tablas de datos. El resultado buscado es una tabla que recoge, para un tipo de alimentación del motor y nivel de carga, todas las amplitudes de los diferentes componentes de frecuencia recogidos en la toma de datos junto con el estado del rodamiento que reflejan los mismos. Las primeras 20 filas reúnen las amplitudes de los 20 ensayos realizados para cada tipo de frecuencia característica de fallo (BPFI, BPFO, BFTF o BFS) cuando el estado de los rodamientos era sano. Las siguientes 15 filas corresponden a las amplitudes cuando el rodamiento presenta un fallo leve. Las 15 filas que se presentan a continuación, representan un fallo moderado del rodamiento. Las 10 siguientes, un fallo grave y las 10 últimas, un fallo muy grave. Por lo tanto, para el análisis a realizar, no se hará distinción entre fallos de las diferentes partes del rodamiento.

La Tabla 7.1 muestra el número de ensayos realizados para cada tipo de fallo en función del tipo de alimentación del motor y nivel de carga.

Alimentación	Nivel de carga	Tipo de fallo	Número de ensayos
RED	NC1	Sano	20 ensayos
		Fallo leve	15 ensayos
		Fallo moderado	15 ensayos
		Fallo grave	10 ensayos
		Fallo muy grave	10 ensayos
	NC2	Sano	20 ensayos
		Fallo leve	15 ensayos
		Fallo moderado	15 ensayos
		Fallo grave	10 ensayos
		Fallo muy grave	10 ensayos

WEG	NC1	Sano	20 ensayos
		Fallo leve	15 ensayos
		Fallo moderado	15 ensayos
		Fallo grave	10 ensayos
		Fallo muy grave	10 ensayos
	NC2	Sano	20 ensayos
		Fallo leve	15 ensayos
		Fallo moderado	15 ensayos
		Fallo grave	10 ensayos
		Fallo muy grave	10 ensayos
AB1 AB2 AB3 AB4	NC1	Sano	20 ensayos
		Fallo leve	15 ensayos
		Fallo moderado	15 ensayos
		Fallo grave	10 ensayos
		Fallo muy grave	10 ensayos
	NC2	Sano	20 ensayos
		Fallo leve	15 ensayos
		Fallo moderado	15 ensayos
		Fallo grave	10 ensayos
		Fallo muy grave	10 ensayos

Tabla 7.1. Número de ensayos en función del tipo de fallo, nivel de carga y tipo de alimentación del motor.

Una vez obtenida la tabla que proporcionan los scripts para el tratamiento de los datos en cada caso ya se pueden manipular los datos para el estudio de ambos tipos de técnicas de Machine Learning.

En el caso de técnicas supervisadas el análisis se llevará a cabo de manera directa, como ya se ha indicado, a través de la APP Classification Learner. Se obtiene así el algoritmo, dentro de los supervisados, que presente mayor precisión a la hora de clasificar los datos en cada caso. Concretamente, el valor que proporciona la APP es la accuracy o exactitud, indicando el porcentaje de acierto del algoritmo. Es decir, el número de ensayos que establece con el estado correcto de todos los ensayos empleados para la validación.

Para estudiar las técnicas no supervisadas, por su parte, se emplearán los algoritmos K-Means, K-Medoids y Hierarchical Clustering, formando parte del grupo “Hard clustering”, en el que los datos pertenecen a un solo grupo, como ocurre en el caso de estudio. Dichos algoritmos precisan que se indique el número de agrupaciones o clusters en los que dividir los datos. En este caso, dicho número será 5, correspondiente a los 5 estados diferentes de los rodamientos. La programación de estos algoritmos se presenta en diferentes scripts recogidos en el Anexo 2, siendo un aspecto importante que la tabla de datos a utilizar no ha de contener el estado de los mismos. Se emplea de este modo la variable “Xdatos”.

El resultado de introducir la variable anterior a los algoritmos no supervisados será una matriz de 70 filas, correspondientes a los 70 ensayos y una columna. El contenido de dicha matriz será un valor por fila, del 1 al 5, representativo del grupo o cluster al que el algoritmo asocia el conjunto de amplitudes de cada ensayo. Comparando este resultado con el verdadero estado que tienen cada grupo de amplitudes, se podrá observar la validez de estas técnicas no supervisadas para el diagnóstico del estado de los rodamientos en motores de inducción.

Por lo tanto, se compararán los resultados de aplicar los algoritmos no supervisados a los datos tomados del motor para cada tipo de alimentación y carga del mismo con los verdaderos estados de los rodamientos para cada ensayo realizado. Para esta tarea se emplearán otros scripts nombrados posteriormente y recogidos en el Anexo 2. Estos scripts proporcionan, en tanto por ciento, el grado de adecuación de los resultados del algoritmo empleado en cada caso respecto de los verdaderos estados.

Para lograr la precisión del algoritmo se emplea una técnica de validación aplicada a este tipo de técnicas no supervisadas, conocida como validación externa. El procedimiento consiste en comparar parejas de ensayos. Esta comparación se lleva a cabo en cada uno de los vectores descritos anteriormente, el de estados reales y el formado por los grupos establecidos por el algoritmo en cuestión. Además, se realiza entre parejas de ensayos de cada vector. En el primer caso, el procedimiento consiste en comparar el estado o grupo al que pertenece cada ensayo con el estado o grupo del resto

de ensayos dentro del mismo vector. En el segundo caso, se compara si cada pareja de ensayos del vector de estados reales presenta o no igual grupo que la pareja de ensayos del otro vector que ocupan la misma posición. Mediante este procedimiento se obtienen una serie de parámetros.

Si llamamos “a” al vector de estados reales y “b” al de estados establecidos por el algoritmo, los parámetros buscados son los siguientes:

TP: Número de pares de datos que presentan igual grupo en a y b.

FP: Numero de pares de datos que presentan igual grupo en b, pero no en a.

FN: Numero de pares de datos que presentan igual grupo en a, pero no en b.

TN: Número de pares de datos que no están en igual grupo ni en a ni en b.

Es necesario tener presente que para que dos pares de ensayos, uno de cada vector, se cuenten como TP no hace falta que pertenezcan a igual estado. Esto se justifica por la naturaleza de las técnicas no supervisadas, generando estas un conjunto de grupos, pero sin atribuirlos un estado en concreto. Lo que se busca, en definitiva, para el parámetro TP, es que ambos pares de ensayos estén asignados en un mismo grupo, aunque entre ellos dicho grupo sea diferente. Para el resto de parámetros, ocurrirá algo semejante.

Denominando como pares de ensayos positivos aquellos que presentan el mismo estado en el vector de estados reales, al tener 70 ensayos y cinco estados posibles, ser el vector de estados reales siempre el mismo y de forma que no se repitan comparaciones de pares de ensayos ni se compare un ensayo consigo mismo, habrá 490 pares de ensayos positivos. De igual modo, el número de pares de conjuntos con diferentes estados es de 1925, siendo el total de pares de ensayos a comparar de 2415. Es decir, si el algoritmo clasificara los datos con una precisión del 100%, el valor de TP sería de 490 y el de TN, de 1925.

Una vez tengo los valores anteriormente descritos, se puede obtener la precisión, el parámetro recall (exhasutividad) y el indicador F1.

Mediante la precisión se compara el número de pares de ensayos diagnosticados como positivos de manera correcta, con el conjunto de todos los pares de ensayos asignados como positivos por el algoritmo. Es decir, compruebo cuántos pares de ensayos se asignan con igual estado correctamente de entre los diagnosticados con dicho carácter por el algoritmo.

Este valor mostrará la calidad de las técnicas no supervisadas a la hora de clasificar los estados, obteniéndose a través de la siguiente fórmula:

$$\text{Precision} = \frac{TP}{TP+FP} \quad (7.3)$$

El parámetro recall o exhaustividad, relaciona el número de positivos con el número total de positivos reales o, dicho de otro modo, el número de pares de ensayos con igual grupo que designa el algoritmo adecuadamente con el número total que realmente presentan igual grupo, recogidos en el vector “a”.

Este segundo valor, expondrá la cantidad de pares de ensayos que el algoritmo es capaz de identificar dentro del mismo grupo de forma correcta.

$$\text{Recall} = \frac{TP}{TP+FN} \quad (7.4)$$

El parámetro F1 relaciona la precisión y la exhaustividad en un solo valor, pudiendo comparar, con mayor facilidad, el rendimiento combinado de varios planteamientos. Se logra con la fórmula mostrada a continuación:

$$F1 = 2 \cdot \frac{\text{precision} \cdot \text{recall}}{\text{precision} + \text{recall}} \quad (7.5)$$

Los resultados obtenidos para cada tipo de alimentación del motor y nivel de carga del mismo, se muestran en el siguiente capítulo. Obteniendo los indicadores anteriores y añadiendo en algunos casos, la matriz de confusión del estudio, indicándose en esta los parámetros TP, FN, TN y FP.

CAPÍTULO 8.

EXPOSICIÓN Y ANÁLISIS DE RESULTADOS.

En este octavo capítulo se trabaja con todos los datos tomados de los diferentes tipos de alimentación del motor y niveles de carga explicados en el capítulo 7. Para ello, como se vio en capítulo anterior, se tienen que adecuar a las funciones de MATLAB mediante scripts empleados para el tratamiento de los datos. Los resultados necesarios para establecer un diagnóstico se obtendrán a través de la APP Clasification Learner en el caso de trabajar con técnicas supervisadas o mediante scripts creados para el análisis de técnicas no supervisadas. Dichos resultados son las precisiones a la hora de clasificar los datos en cada caso y la matriz de confusión.

Antes de exponer cada caso, se ha de tener presente que los resultados obtenidos por los algoritmos variarán en cada llamada a la función. Por ejemplo, el funcionamiento del algoritmo K-Means, como se vio en el Capítulo 6, consiste en fijar en un primer momento de manera aleatoria en el conjunto de datos tantos puntos como agrupaciones se deseen. Dichos puntos serán diferentes cada vez que se emplee el algoritmo, aunque se introduzcan los mismos datos. Por lo tanto, los resultados mostrados a continuación son los obtenidos de una llamada al algoritmo. No teniendo que ser ni el peor ni el mejor resultado posible.

8.1. ANÁLISIS DEL COMPORTAMIENTO DE LAS TÉCNICAS NO SUPERVISADAS. ALGORITMO K-MEANS.

Con el objetivo de que el estudio sea más completo, se estudiará la respuesta de este algoritmo no supervisado frente a diferentes agrupaciones de estados de los datos. Atendiendo a la clasificación de los estados del rodamiento establecida en el Capítulo 7, se ensayarán los siguientes casos:

- Dos estados: - Rodamiento sano.
- Resto de estados.
- Tres estados: - Rodamiento sano.
- Fallo leve y fallo moderado.
- Fallo grave y rodamiento totalmente destruido.
- Cinco estados diferentes.

8.1.1 COMPORTAMIENTO DEL ALGORITMO FRENTE A RODAMIENTOS SANOS Y PRESENCIA DE FALLOS.

En este apartado vamos a analizar cómo responde el algoritmo no supervisado elegido frente a la clasificación de los datos en dos estados. El objetivo es simplificar la clasificación de los datos, observando el comportamiento del algoritmo y pudiéndolo comparar con el que presentará cuando los estados posibles sean los indicados en la introducción al capítulo.

Se considerarán los datos del motor con estado sano aquellos que pertenecen a los 20 primeros ensayos y con estado de presencia de fallo, sin distinción de su importancia, los que componen el resto de ensayos, es decir, desde el 21 al 70.

En la tarea anterior, se empleará el “Script_Tratamiento_Datos_Sano_Fallos” para el tratamiento adecuado de los datos y el “Script_Concordancia_Sano_Fallos” para la evaluación de la clasificación realizada por el algoritmo. Ambos scripts se muestran en el Anexo2.

A continuación, se mostrarán la precisión, exhaustividad y el factor F1 a la hora de clasificar los datos de entrada, así como la matriz de confusión de cada uno de los posibles tipos de alimentación y niveles de carga.

MOTOR ALIMENTADO DIRECTAMENTE DE RED CON NIVEL DE CARGA NOMINAL.

Con el motor alimentado directamente de la red eléctrica y estando la carga en su nivel nominal, la precisión del algoritmo a la hora de clasificar las amplitudes de las componentes de frecuencias entre estado sano o presencia de fallos es del 56.67%, el valor de recall del 81.34% y un F1 del 66.8%. La matriz de confusión y los parámetros TP, FP, FN, TN se muestra en la Figura 8.1.

		AGRUPACIÓN GENERADA	
		1	0
AGRUPACIÓN REAL	1	TP=1151	FN=264
	0	FP=880	TN=120

Figura 8.1. Matriz de confusión y parámetros asociados de los datos RED_NC2 para dos estados.

En este caso, el algoritmo clasifica en el mismo grupo de manera adecuada el 56.67% de los pares de ensayos entre todos los que considera del mismo conjunto y con un 81.34% de la totalidad de positivos reales.

La matriz de confusión está formada, como se ve, por dos filas y dos columnas. Los estados reales se presentan de manera vertical mientras que los predichos de forma horizontal. Los datos se clasifican en los estados 1 y 2. El primero corresponde a un estado sano de los rodamientos y el segundo a la presencia de fallos en los mismos.

Se observa que el número de pares de ensayos asignados correctamente es de 1151, siendo el número de ensayos con igual grupo en a, pero no en b, de 264. Si sumamos ambos valores, conseguimos el número total de positivos en el caso de considerar dos estados, 1415. Se obtiene, con estos valores, la precisión indicada.

Por otro lado, el número de pares de ensayos que no comparten estado ni en a ni en b, es de 220 y el número que el algoritmo considera con igual cluster de manera equivocada, de 880. Sumando ambos valores, obtenemos los 1000 pares de ensayos que no comparten estado.

Finalmente, si sumamos todos los parámetros, obtenemos 2415, el número total de comparaciones realizadas.

MOTOR ALIMENTADO DIRECTAMENTE DE RED CON NIVEL DE CARGA BAJO.

En este caso, el algoritmo clasifica los datos con una precisión del 56.4%, una exhaustividad del 70.8% y un F1 del 61.16%, siendo la matriz de confusión y sus parámetros asociados los mostrados en la Figura 8.2.

		AGRUPACIÓN GENERADA	
		1	0
AGRUPACIÓN REAL	1	TP=996	FN=419
	0	FP=770	TN=230

Figura 8.2. Matriz de confusión y parámetros asociados de los datos RED_NC1 para dos estados.

En esta segunda configuración, la precisión es del 56.4% y el parámetro recall o la exhaustividad, del 70.8%. Se ve, como pasaba en el caso anterior, que este último valor es mayor que la precisión. Es decir, el algoritmo tiene un mayor porcentaje de acierto respecto al total de positivos que frente al conjunto de pares que se consideran con mismo grupo. Esto refleja que se consideran con igual estado, de manera errónea, un mayor porcentaje de pares de ensayos que el porcentaje que no se asignan dentro del mismo cluster de manera equivocada. El valor de FN, por esta razón, es menos que FP.

Si se compara con el caso anterior, el número de positivos diagnosticados y de falsos positivos es menor, siendo mayor el de falsos negativo, ocasionando una precisión, una exhaustividad y un F1, inferiores.

MOTOR ALIMENTADO MEDIANTE UN VARIADOR DE FRECUENCIA WEG CON NIVEL DE CARGA NOMINAL.

Frente a esta configuración se obtiene una precisión del 59.12 %, una exhaustividad del 66.43% y un F1 del 62.56%, siendo la matriz de confusión y sus parámetros asociados los mostrados en la Figura 8.3.

		AGRUPACIÓN GENERADA	
		1	0
AGRUPACIÓN REAL	1	TP=940	FN=475
	0	FP=650	TN=350

Figura 8.3. Matriz de confusión y parámetros asociados de los datos WEG_NC2 para dos estados.

Al alimentar al motor mediante un convertidor WEG, el algoritmo clasifica adecuadamente casi el 60% de los pares de datos positivos y casi el 67% de los datos que se consideran con igual estado, logrando un F1 del 62.56%.

Respecto a la alimentación del motor directamente desde red, con igual nivel de carga, se logra un pequeño aumento de la precisión, una disminución de la exhaustividad y del factor F1.

MOTOR ALIMENTADO MEDIANTE UN VARIADOR DE FRECUENCIA WEG CON NIVEL DE CARGA BAJO.

Para este tipo de alimentación y nivel de carga el algoritmo logra una precisión del 56.43 %, una exhaustividad del 78.73% y un F1 del 65.74%, siendo la matriz de confusión y sus parámetros asociados los mostrados en la Figura 8.4.

		AGRUPACIÓN GENERADA	
		1	0
AGRUPACIÓN REAL	1	TP=1114	FN=301
	0	FP=860	TN=140

Figura 8.4. Matriz de confusión y parámetros asociados de los datos WEG_NC1 para dos estados.

Destaca una elevada exhaustividad, clasificando el 78.73% de los pares del total de ensayos positivos correctamente.

MOTOR ALIMENTADO MEDIANTE UN VARIADOR DE FRECUENCIA AB1 CON NIVEL DE CARGA NOMINAL.

En esta ocasión el algoritmo clasifica los datos con una precisión del 58.47 %, una exhaustividad del 55.12% y un F1 de 56.74%, siendo la matriz de confusión y sus parámetros asociados los mostrados en la Figura 8.5.

		AGRUPACIÓN GENERADA	
		1	0
AGRUPACIÓN REAL	1	TP=780	FN=635
	0	FP=554	TN=446

Figura 8.5. Matriz de confusión y parámetros asociados de los datos AB1_NC2 para dos estados.

MOTOR ALIMENTADO MEDIANTE UN VARIADOR DE FRECUENCIA AB1 CON NIVEL DE CARGA BAJO.

Para este tipo de alimentación y nivel de carga el algoritmo logra una precisión del 57.23 %, una exhaustividad del 87% y un F1 del 69.04%, siendo la matriz de confusión y sus parámetros asociados los mostrados en la Figura 8.6.

		AGRUPACIÓN GENERADA	
		1	0
AGRUPACIÓN REAL	1	TP=1231	FN=184
	0	FP=920	TN=80

Figura 8.6. Matriz de confusión y parámetros asociados de los datos AB1_NC1 para dos estados.

MOTOR ALIMENTADO MEDIANTE UN VARIADOR DE FRECUENCIA AB2 CON NIVEL DE CARGA NOMINAL.

Ahora el algoritmo clasifica los datos con una precisión del 56.1 %, una exhaustividad del 63 % y un F1 del 59.35%, siendo la matriz de confusión y sus parámetros asociados los mostrados en la Figura 8.7.

		AGRUPACIÓN GENERADA	
		1	0
AGRUPACIÓN REAL	1	TP=892	FN=523
	0	FP=698	TN=302

Figura 8.7. Matriz de confusión y parámetros asociados de los datos AB2_NC2 para dos estados.

MOTOR ALIMENTADO MEDIANTE UN VARIADOR DE FRECUENCIA AB2 CON NIVEL DE CARGA BAJO.

Con igual alimentación que en el caso anterior, pero nivel de carga bajo, el algoritmo clasifica los datos con una precisión del 56,6 %, una exhaustividad del 65,23% y un F1 del 60.6%, siendo la matriz de confusión y sus parámetros asociados los mostrados en la Figura 8.8.

		AGRUPACIÓN GENERADA	
		1	0
AGRUPACIÓN REAL	1	TP=923	FN=492
	0	FP=708	TN=292

Figura 8.8. Matriz de confusión y parámetros asociados de los datos AB2_NC1 para dos estados.

MOTOR ALIMENTADO MEDIANTE UN VARIADOR DE FRECUENCIA AB3 CON NIVEL DE CARGA NOMINAL.

Para este tipo de alimentación y nivel de carga el algoritmo logra una precisión del 69.33 %, una exhaustividad del 60,70% y un F1 del 64.73%, siendo la matriz de confusión y sus parámetros asociados los mostrados en la Figura 8.9.

		AGRUPACIÓN GENERADA	
		1	0
AGRUPACIÓN REAL	1	TP=859	FN=556
	0	FP=380	TN=620

Figura 8.9. Matriz de confusión y parámetros asociados de los datos AB3_NC2 para dos estados.

MOTOR ALIMENTADO MEDIANTE UN VARIADOR DE FRECUENCIA AB3 CON NIVEL DE CARGA BAJO.

El algoritmo clasifica los datos con una precisión del 70,2 %, una exhaustividad del 59 % y un F1 del 64.11%, siendo la matriz de confusión y sus parámetros asociados los mostrados en la Figura 8.10.

		AGRUPACIÓN GENERADA	
		1	0
AGRUPACIÓN REAL	1	TP=835	FN=580
	0	FP=356	TN=644

Figura 8.10. Matriz de confusión y parámetros asociados de los datos AB3_NC1 para dos estados.

MOTOR ALIMENTADO MEDIANTE UN VARIADOR DE FRECUENCIA AB4 CON NIVEL DE CARGA NOMINAL.

Para este último tipo de alimentación el algoritmo clasifica los datos con una precisión del 55.93 %, una exhaustividad del 71.73% y un F1 del 62.85%, siendo la matriz de confusión y sus parámetros asociados los mostrados en la Figura 8.11.

		AGRUPACIÓN GENERADA	
		1	0
AGRUPACIÓN REAL	1	TP=1015	FN=400
	0	FP=800	TN=200

Figura 8.11. Matriz de confusión y parámetros asociados de los datos AB4_NC2 para dos estados.

MOTOR ALIMENTADO MEDIANTE UN VARIADOR DE FRECUENCIA AB4 CON NIVEL DE CARGA BAJO.

En este caso, el algoritmo clasifica los datos con una precisión del 62.85 %, una exhaustividad del 56.67% y un F1 del 59.6 % siendo la matriz de confusión y sus parámetros asociados los mostrados en la Figura 8.12.

		AGRUPACIÓN GENERADA	
		1	0
AGRUPACIÓN REAL	1	TP=1151	FN=264
	0	FP=880	TN=120

Figura 8.12. Matriz de confusión y parámetros asociados de los datos AB4_NC1 para dos estados.

En la Tabla 8.1 se recopilan los resultados del algoritmo K-Means obtenidos para cada tipo de alimentación y nivel de carga.

Alimentación	Nivel de carga	Precisión (%)	Recall (%)	F1 (%)
RED	NC2	56.67	81.34	66.8
	NC1	56.4	70.8	56.4

WEG	NC2	59.12	66.43	62.56
	NC1	56.43	78.73	65.74
AB1	NC2	58.47	55.12	56.74
	NC1	57.23	87	69.04
AB2	NC2	56.1	63	59.35
	NC1	56.6	65.23	60.6
AB3	NC2	69.33	60.7	64.73
	NC1	70.2	59	64.11

AB4	NC2	55.93	71.73	62.85
	NC1	62.85	56.67	59.6

Tabla 8.1. Precisión, exhaustividad y F1 de K-Means para ensayos clasificados en dos estados.

Los resultados que a priori se pueden esperar del comportamiento del algoritmo frente a la clasificación de los diferentes estados de los rodamientos, son los siguientes:

- Mejor respuesta cuando el motor esté alimentado directamente de red que a través de un convertidor de frecuencia. Este último, como ya se ha visto, introduce una serie de nuevos armónicos al espectro, complicando así la clasificación.
- Mejor comportamiento del algoritmo cuando el motor está consumiendo su carga nominal que cuando la carga que consume es baja.
- En cuanto a la frecuencia de alimentación de la onda que sale de los convertidores de frecuencia, se obtendrán peores resultados si la misma es diferente a 50 Hz al introducir una mayor cantidad de armónicos.
- Respecto a la frecuencia de conmutación de los convertidores, cuanto mayor sea esta, la onda de salida será más semejante a una senoidal, introduciendo mayor contenido armónico, dificultando la clasificación.

En el caso tratado en este apartado, en el que los estados del rodamiento se clasifican en sanos y presencia de fallo, los resultados, en relación a lo expuesto anteriormente, son:

- En cuanto a la precisión del algoritmo en la clasificación de los datos, se observa que no son muy elevadas en ningún caso, estando en torno al 50-60%. Respecto a la exhaustividad, su valor es, de manera general, mayor que la precisión, siendo de valores entre el 50% y el 80%. Esto

indica que, de forma general, presenta un alto porcentaje de acierto a la hora de identificar pares de ensayos que pertenecen a igual grupo, pero asigna a un gran número de pares de conjuntos el mismo grupo de manera equivocada. Con ambos parámetros, se logra un F1 en torno al 60-70%.

- La precisión, para un nivel de carga nominal, es algo menor si se alimenta de red y no se observan grandes diferencias si el nivel de carga es bajo, estando en torno al 56%. Respecto a la exhaustividad, en el caso de alimentación directa de red, es mejor que en el caso de alimentación mediante cualquier tipo de convertidor si el nivel de carga es el nominal, siendo peor si este es bajo, sucediendo lo mismo con F1.
- Desde el punto de vista del nivel de carga, la exhaustividad y F1 son mayores con un nivel nominal para los casos de alimentación de red, AB3 y AB4. En el resto de casos, se logran mejores resultados si el nivel es bajo. Por su parte, la precisión es mayor en la alimentación mediante el convertidor WEG si el nivel de carga es el nominal, mayor en AB4 si este es bajo y sin demasiada discrepancia en el resto de los casos.
- En cuanto a la comparativa de convertidores en iguales condiciones, se obtiene una precisión semejante en ambos, en torno al 56%. La exhaustividad, en casi todos los casos, presenta mayor valor para el convertidor WEG. Con este último, F1 es mayor con carga nominal.
- Se obtienen mejores resultados de precisión empleando una frecuencia de alimentación de 75 Hz que una de 25 o 50 Hz. Con un nivel de carga bajo, la exhaustividad y F1 son mayores con 50 Hz y con un nivel de carga nominal, la exhaustividad con 25 Hz y F1 con 75 Hz.
- Por último, para un nivel de carga nominal, el factor F1 es mayor con 5 kHz de frecuencia de conmutación, siendo, con carga baja, mayor con 4 kHz.

8.1.2 COMPORTAMIENTO DEL ALGORITMO FRENTE A TRES ESTADOS DE LOS RODAMIENTOS.

En este apartado se analizarán las respuestas del algoritmo K-Means frente a una agrupación de los datos en tres estados: uno de ellos lo conformarán los ensayos en los que el estado del rodamiento era sano, el segundo estará formado por los estados fallo leve y fallo moderado y el último, por los ensayos donde el rodamiento presentaba un fallo grave y en los que estaba totalmente destruido. De este modo se considerarán con igual estado los 20 primeros ensayos, los 30 siguientes y los 20 últimos. Frente a esta nueva agrupación de

datos es necesario crear un nuevo script para el tratamiento de datos y otro para la obtención de la eficiencia del algoritmo en cada caso. Ambos scripts, nombrados como “Script_Tratamiento_Datos_TresEstados” y “Script_Concordancia_TresEstados” se recogen en el Anexo 2.

Los resultados obtenidos para cada tipo de alimentación y nivel de carga en este caso se muestran en los apartados siguientes de igual modo que en el caso de sólo considerar dos estados posibles.

MOTOR ALIMENTADO DIRECTAMENTE DE RED CON NIVEL DE CARGA NOMINAL.

La precisión obtenida es del 52.62%, una exhaustividad del 77.67% y un F1 del 62.74%, siendo la matriz de confusión y sus parámetros asociados los mostrados en la Figura 8.13.

		AGRUPACIÓN GENERADA	
		1	0
AGRUPACIÓN REAL	1	TP=633	FN=182
	0	FP=570	TN=1030

Figura 8.13. Matriz de confusión y parámetros asociados de los datos RED_NC2 para tres estados.

Para este primer tipo de alimentación y nivel de carga, la precisión es del 52.62% y el parámetro recall o la exhaustividad, del 77.67%. Se muestra una mayor precisión a la hora de identificar pares de ensayos pertenecientes al mismo grupo respecto del total. Por su parte, la calidad del algoritmo en cuanto a acertar en la asignación adecuada de pares de conjuntos con igual estado dentro de todos los que designa, reflejado por la precisión, es menor.

La suma de los valores de TP y FN es de 815, correspondiendo al número de pares de ensayos con igual estado para el caso de considerar tres estados. Si se suma FP y TN, obtenemos 1600, el número de negativos.

MOTOR ALIMENTADO DIRECTAMENTE DE RED CON NIVEL DE CARGA BAJO.

La precisión obtenida es del 36.49%, una exhaustividad del 67 % y un F1 del 47.24%, siendo la matriz de confusión y sus parámetros asociados los mostrados en la Figura 8.14.

		AGRUPACIÓN GENERADA	
		1	0
AGRUPACIÓN REAL	1	TP=546	FN=269
	0	FP=950	TN=650

Figura 8.14. Matriz de confusión y parámetros asociados de los datos RED_NC1 para tres estados.

MOTOR ALIMENTADO MEDIANTE UN VARIADOR DE FRECUENCIA WEG CON NIVEL DE CARGA NOMINAL.

La precisión obtenida es del 54.79%, una exhaustividad del 74.36% y un F1 del 63.09%, siendo la matriz de confusión y sus parámetros asociados los mostrados en la Figura 8.15.

		AGRUPACIÓN GENERADA	
		1	0
AGRUPACIÓN REAL	1	TP=606	FN=209
	0	FP=500	TN=1100

Figura 8.15. Matriz de confusión y parámetros asociados de los datos WEG_NC2 para tres estados.

MOTOR ALIMENTADO MEDIANTE UN VARIADOR DE FRECUENCIA WEG CON NIVEL DE CARGA BAJO.

La precisión obtenida es del 37.65%, una exhaustividad del 77.79% y un F1 del 50.74%, siendo la matriz de confusión y sus parámetros asociados los mostrados en la Figura 8.16.

		AGRUPACIÓN GENERADA	
		1	0
AGRUPACIÓN REAL	1	TP=634	FN=181
	0	FP=550	TN=1050

Figura 8.16. Matriz de confusión y parámetros asociados de los datos WEG_NC1 para tres estados.

MOTOR ALIMENTADO MEDIANTE UN VARIADOR DE FRECUENCIA AB1 CON NIVEL DE CARGA NOMINAL.

La precisión obtenida es del 50.74%, una exhaustividad del 76.1% y un F1 del 60.88%, siendo la matriz de confusión y sus parámetros asociados los mostrados en la Figura 8.17.

		AGRUPACIÓN GENERADA	
		1	0
AGRUPACIÓN REAL	1	TP=620	FN=195
	0	FP=602	TN=998

Figura 8.17. Matriz de confusión y parámetros asociados de los datos AB1_NC2 para tres estados.

MOTOR ALIMENTADO MEDIANTE UN VARIADOR DE FRECUENCIA AB1 CON NIVEL DE CARGA BAJO.

La precisión obtenida es del 45.38%, una exhaustividad del 77.18% y un F1 del 57.15%, siendo la matriz de confusión y sus parámetros asociados los mostrados en la Figura 8.18.

		AGRUPACIÓN GENERADA	
		1	0
AGRUPACIÓN REAL	1	TP=629	FN=186
	0	FP=757	TN=843

Figura 8.18. Matriz de confusión y parámetros asociados de los datos AB1_NC1 para tres estados.

MOTOR ALIMENTADO MEDIANTE UN VARIADOR DE FRECUENCIA AB2 CON NIVEL DE CARGA NOMINAL.

La precisión obtenida es del 60.95%, una exhaustividad del 62.82% y un F1 del 61.87%, siendo la matriz de confusión y sus parámetros asociados los mostrados en la Figura 8.19.

		AGRUPACIÓN GENERADA	
		1	0
AGRUPACIÓN REAL	1	TP=512	FN=303
	0	FP=328	TN=1272

Figura 8.19. Matriz de confusión y parámetros asociados de los datos AB2_NC2 para tres estados.

MOTOR ALIMENTADO MEDIANTE UN VARIADOR DE FRECUENCIA AB2 CON NIVEL DE CARGA BAJO.

La precisión obtenida es del 43.8%, una exhaustividad del 48.95% y un F1 del 46.23%, siendo la matriz de confusión y sus parámetros asociados los mostrados en la Figura 8.20.

		AGRUPACIÓN GENERADA	
		1	0
AGRUPACIÓN REAL	1	TP=399	FN=416
	0	FP=1088	TN=512

Figura 8.20. Matriz de confusión y parámetros asociados de los datos AB2_NC1 para tres estados.

MOTOR ALIMENTADO MEDIANTE UN VARIADOR DE FRECUENCIA AB3 CON NIVEL DE CARGA NOMINAL.

La precisión obtenida es del 39.69%, una exhaustividad del 59.02% y un F1 del 47.46%, siendo la matriz de confusión y sus parámetros asociados los mostrados en la Figura 8.21.

		AGRUPACIÓN GENERADA	
		1	0
AGRUPACIÓN REAL	1	TP=481	FN=334
	0	FP=731	TN=869

Figura 8.21. Matriz de confusión y parámetros asociados de los datos AB3_NC2 para tres estados.

MOTOR ALIMENTADO MEDIANTE UN VARIADOR DE FRECUENCIA AB3 CON NIVEL DE CARGA BAJO.

La precisión obtenida es del 33.67%, una exhaustividad del 65.4% y un F1 del 44.45%, siendo la matriz de confusión y sus parámetros asociados los mostrados en la Figura 8.22.

		AGRUPACIÓN GENERADA	
		1	0
AGRUPACIÓN REAL	1	TP=533	FN=282
	0	FP=1050	TN=550

Figura 8.22. Matriz de confusión y parámetros asociados de los datos AB3_NC1 para tres estados.

MOTOR ALIMENTADO MEDIANTE UN VARIADOR DE FRECUENCIA AB4 CON NIVEL DE CARGA NOMINAL.

La precisión obtenida es del 48.86%, una exhaustividad del 63.31% y un F1 del 55.17%, siendo la matriz de confusión y sus parámetros asociados los mostrados en la Figura 8.23.

		AGRUPACIÓN GENERADA	
		1	0
AGRUPACIÓN REAL	1	TP=516	FN=299
	0	FP=1060	TN=540

Figura 8.23. Matriz de confusión y parámetros asociados de los datos AB4_NC2 para tres estados.

MOTOR ALIMENTADO MEDIANTE UN VARIADOR DE FRECUENCIA AB4 CON NIVEL DE CARGA BAJO.

La precisión obtenida es del 33.94%, una exhaustividad del 81.96% y un F1 del 48%, siendo la matriz de confusión y sus parámetros asociados los mostrados en la Figura 8.24.

		AGRUPACIÓN GENERADA	
		1	0
AGRUPACIÓN REAL	1	TP=668	FN=147
	0	FP=1300	TN=300

Figura 8.24. Matriz de confusión y parámetros asociados de los datos AB4_NC1 para tres estados.

La precisión, la exhaustividad y el parámetro F1 obtenidos en cada uno de los casos anteriores se recogen en la Tabla 8.2.

Alimentación	Nivel de carga	Precisión (%)	Recall (%)	F1 (%)
RED	NC2	52.62	77.67	62.74
	NC1	36.49	67	47.24

WEG	NC2	54.79	74.36	63.09
	NC1	37.65	77.79	50.74
AB1	NC2	50.74	76.1	60.88
	NC1	45.38	77.18	57.15
AB2	NC2	60.95	62.82	61.87
	NC1	43.8	48.95	46.23

AB3	NC2	39.69	59.02	47.46
	NC1	33.67	65.4	44.45
AB4	NC2	48.86	63.31	55.17
	NC1	33.94	81.96	48

Tabla 8.2. Precisión, exhaustividad y F1 de K-Means para ensayos clasificados en tres estados.

Si se observan los valores en el caso de considerar dos estados y tres, se puede ver que, en este último caso, son inferiores en la mayoría de las configuraciones posibles. Esto se observa fácilmente mediante los valores que adquiere el parámetro F1 en cada caso. Este comportamiento del algoritmo es el esperado, ya que, al introducir tres estados, diferenciando dos gravedades de fallo, la clasificación se vuelve más complicada debido la mayor similitud entre los datos que en el caso de tan solo considerar estados sanos y presencia de fallos.

Se comprueba que, en cuanto a la precisión y F1, en la mayoría de casos, el algoritmo responde mejor cuando la carga es nominal. Con el valor de recall, sucede lo mismo en los casos RED y AB2, es menor para AB3 y AB4 y presenta un valor semejante en el resto.

Por otro lado, no se denota gran mejoría cuando el motor es alimentado de red, incluso la precisión y el valor de F1 son peores comparados con los logrados en el caso del empleo de un convertidor WEG con carga nominal.

Además, en casi todos los casos se logran mayores valores de F1 mediante el convertidor Allen Bradley cuando las frecuencias de alimentación son de 50 Hz que cuando son 25 y 75 Hz.

Por último, los valores obtenidos son mayores si la frecuencia de conmutación es de 4kHz frente a 5kHz.

8.1.3 COMPORTAMIENTO DEL ALGORITMO FRENTE A CINCO ESTADOS DE LOS RODAMIENTOS.

En este último caso de estudio del algoritmo K-Means se empleará la clasificación original de los estados de los rodamientos, es decir, en cinco estados. Para el tratamiento de los datos y la obtención de la precisión se utilizarán los scripts “Script_Tratamiento_Datos” y “Script_Concordancia” respectivamente, ambos mostrados en el Anexo 2.

De igual manera que en los casos anteriores, a continuación, se muestran los resultados para cada tipo de alimentación y nivel de carga considerados.

MOTOR ALIMENTADO DIRECTAMENTE DE RED, CON NIVEL DE CARGA NOMINAL.

La precisión obtenida es del 46.32%, una exhaustividad del 47.55% y un F1 del 46.93%, siendo la matriz de confusión y sus parámetros asociados los mostrados en la Figura 8.25.

		AGRUPACIÓN GENERADA	
		1	0
AGRUPACIÓN REAL	1	TP=233	FN=257
	0	FP=270	TN=1655

Figura 8.25. Matriz de confusión y parámetros asociados de los datos RED_NC2 para cinco estados.

MOTOR ALIMENTADO DIRECTAMENTE DE RED CON NIVEL DE CARGA BAJO.

La precisión obtenida es del 42.75%, una exhaustividad del 48.16% y un F1 del 45.29%, siendo la matriz de confusión y sus parámetros asociados los mostrados en la Figura 8.26.

		AGRUPACIÓN GENERADA	
		1	0
AGRUPACIÓN REAL	1	TP=236	FN=254
	0	FP=316	TN=1609

Figura 8.26. Matriz de confusión y parámetros asociados de los datos RED_NC1 para cinco estados.

MOTOR ALIMENTADO MEDIANTE UN VARIADOR DE FRECUENCIA WEG CON NIVEL DE CARGA NOMINAL.

La precisión obtenida es del 36.17%, una exhaustividad del 55.51% y un F1 del 43.8%, siendo la matriz de confusión y sus parámetros asociados los mostrados en la Figura 8.27.

		AGRUPACIÓN GENERADA	
		1	0
AGRUPACIÓN REAL	1	TP=272	FN=218
	0	FP=480	TN=1445

Figura 8.27. Matriz de confusión y parámetros asociados de los datos WEG_NC2 para cinco estados.

MOTOR ALIMENTADO MEDIANTE UN VARIADOR DE FRECUENCIA WEG CON NIVEL DE CARGA BAJO.

La precisión obtenida es del 30.18%, una exhaustividad del 38.37% % y un F1 del 33.78%, siendo la matriz de confusión y sus parámetros asociados los mostrados en la Figura 8.28.

		AGRUPACIÓN GENERADA	
		1	0
AGRUPACIÓN REAL	1	TP=188	FN=302
	0	FP=435	TN=1490

Figura 8.28. Matriz de confusión y parámetros asociados de los datos WEG_NC1 para cinco estados.

MOTOR ALIMENTADO MEDIANTE UN VARIADOR DE FRECUENCIA AB1 CON NIVEL DE CARGA NOMINAL.

La precisión obtenida es del 20%, una exhaustividad del 67% % y un F1 del 30.8%, siendo la matriz de confusión y sus parámetros asociados los mostrados en la Figura 8.29.

		AGRUPACIÓN GENERADA	
		1	0
AGRUPACIÓN REAL	1	TP=235	FN=255
	0	FP=303	TN=1622

Figura 8.29. Matriz de confusión y parámetros asociados de los datos AB1_NC2 para cinco estados.

MOTOR ALIMENTADO MEDIANTE UN VARIADOR DE FRECUENCIA AB1 CON NIVEL DE CARGA BAJO.

La precisión obtenida es del 41.14%, una exhaustividad del 67.75% % y un F1 del 50.61%, siendo la matriz de confusión y sus parámetros asociados los mostrados en la Figura 8.30.

		AGRUPACIÓN GENERADA	
		1	0
AGRUPACIÓN REAL	1	TP=332	FN=158
	0	FP=475	TN=1450

Figura 8.30. Matriz de confusión y parámetros asociados de los datos AB1_NC1 para cinco estados.

MOTOR ALIMENTADO MEDIANTE UN VARIADOR DE FRECUENCIA AB2 CON NIVEL DE CARGA NOMINAL.

La precisión obtenida es del 50.84%, una exhaustividad del 73.67% % y un F1 del 60.16%, siendo la matriz de confusión y sus parámetros asociados los mostrados en la Figura 8.31.

		AGRUPACIÓN GENERADA	
		1	0
AGRUPACIÓN REAL	1	TP=361	FN=129
	0	FP=349	TN=1576

Figura 8.31. Matriz de confusión y parámetros asociados de los datos AB2_NC2 para cinco estados.

MOTOR ALIMENTADO MEDIANTE UN VARIADOR DE FRECUENCIA AB2 CON NIVEL DE CARGA BAJO.

La precisión obtenida es del 62.17%, una exhaustividad del 68.77% % y un F1 del 65.3%, siendo la matriz de confusión y sus parámetros asociados los mostrados en la Figura 8.32.

		AGRUPACIÓN GENERADA	
		1	0
AGRUPACIÓN REAL	1	TP=337	FN=153
	0	FP=205	TN=1720

Figura 8.32. Matriz de confusión y parámetros asociados de los datos AB2_NC1 para cinco estados.

MOTOR ALIMENTADO MEDIANTE UN VARIADOR DE FRECUENCIA AB3 CON NIVEL DE CARGA NOMINAL.

La precisión obtenida es del 24.86%, una exhaustividad del 47.35% % y un F1 del 32.6%, siendo la matriz de confusión y sus parámetros asociados los mostrados en la Figura 8.33.

		AGRUPACIÓN GENERADA	
		1	0
AGRUPACIÓN REAL	1	TP=232	FN=258
	0	FP=701	TN=1224

Figura 8.33. Matriz de confusión y parámetros asociados de los datos AB3_NC2 para cinco estados.

MOTOR ALIMENTADO MEDIANTE UN VARIADOR DE FRECUENCIA AB3 CON NIVEL DE CARGA BAJO.

La precisión obtenida es del 61.35%, una exhaustividad del 62.86% y un F1 del 62.1%, siendo la matriz de confusión y sus parámetros asociados los mostrados en la Figura 8.34.

		AGRUPACIÓN GENERADA	
		1	0
AGRUPACIÓN REAL	1	TP=308	FN=182
	0	FP=194	TN=1731

Figura 8.34. Matriz de confusión y parámetros asociados de los datos AB3_NC1 para cinco estados.

MOTOR ALIMENTADO MEDIANTE UN VARIADOR DE FRECUENCIA AB4 CON NIVEL DE CARGA NOMINAL.

La precisión obtenida es del 36.86%, una exhaustividad del 72.45% y un F1 del 48.86%, siendo la matriz de confusión y sus parámetros asociados los mostrados en la Figura 8.35.

		AGRUPACIÓN GENERADA	
		1	0
AGRUPACIÓN REAL	1	TP=355	FN=135
	0	FP=608	TN=1317

Figura 8.35. Matriz de confusión y parámetros asociados de los datos AB4_NC2 para cinco estados.

MOTOR ALIMENTADO MEDIANTE UN VARIADOR DE FRECUENCIA AB4 CON NIVEL DE CARGA BAJO.

La precisión obtenida es del 24.31%, una exhaustividad del 77.55% y un F1 del 37.01%, siendo la matriz de confusión y sus parámetros asociados los mostrados en la Figura 8.36.

		AGRUPACIÓN GENERADA	
		1	0
AGRUPACIÓN REAL	1	TP=380	FN=110
	0	FP=1183	TN=742

Figura 8.36. Matriz de confusión y parámetros asociados de los datos AB4_NC1 para cinco estados.

Las precisiones, los valores de exhaustividad y de F1 obtenidos en cada uno de los casos anteriores se recogen en la Tabla 8.3.

Alimentación	Nivel de carga	Precisión (%)	Recall (%)	F1 (%)
RED	NC2	46.32	47.55	46.93
	NC1	42.75	48.16	45.29

WEG	NC2	36.17	55.15	43.8
	NC1	30.18	38.37	33.78
AB1	NC2	20	67	30.8
	NC1	41.14	67.75	50.16
AB2	NC2	50.84	73.67	60.16
	NC1	62.17	68.77	65.3

AB3	NC2	24.86	47.35	32.6
	NC1	61.35	62.86	62.1
AB4	NC2	36.86	72.45	48.86
	NC1	24.31	77.55	37.01

Tabla 8.3. Precisión, exhaustividad y F1 de K-Means para ensayos clasificados en cinco estados.

Como se puede observar, al evaluar al algoritmo con la clasificación de los datos en sus cinco estados originales, en la mayor parte de los casos la precisión, la exhaustividad y el valor de F1 decrece en comparación con los otros dos casos de estudio. Esto es esperado al aumentar la complejidad en la clasificación de los mismos por ser los datos más semejantes que en el caso de considerar tres estados y más aún en el caso de dos.

Aunque, como se ha comentado, los resultados del algoritmo mejoran en el caso de establecer una clasificación de los estados del rodamiento menos concreta, dichos valores no son demasiado buenos. Si de manera general se considera que la precisión ronda en torno al 60% y la exhaustividad, en torno al 70%, se trataría de unos valores que no garantizarían un adecuado

diagnóstico al estado del motor en cuestión. Esto supondría posibles pérdidas de tiempo de producción, averías y otras consecuencias ya indicadas de una mala actuación de mantenimiento. En el caso del último análisis realizado con cinco estados posibles de los rodamientos, siendo el más completo y el más interesante a la hora de efectuar tareas de mantenimiento real, se observa que los resultados son aún peores.

En la Tabla 8.4 se unen los resultados de F1 obtenidos en los apartados 8.1.1, 8.1.2 y 8.1.3, pudiendo comparar, junto con lo expuesto sobre la precisión y la exhaustividad, las diferentes configuraciones llevadas a cabo.

Alimentación	Nivel de carga	F1 (%) 2 estados	F1 (%) 3 estados	F1 (%) 5 estados
RED	NC2	66.8	62.74	46.93
	NC1	56.4	47.24	45.29
WEG	NC2	62.56	63.09	43.8
	NC1	65.74	50.74	33.78

AB1	NC2	56.74	60.88	30.8
	NC1	69.04	57.15	50.16
AB2	NC2	59.35	61.87	60.16
	NC1	60.6	46.23	65.3
AB3	NC2	64.73	47.46	32.6
	NC1	64.11	44.45	62.1

AB4	NC2	62.85	55.17	48.86
	NC1	59.6	48	37.01

Tabla 8.4. Factor F1 de K-Medoids para ensayos clasificados en dos, tres y cinco estados.

Como método de corroboración de los presentes resultados, se ha llevado a cabo el análisis de las respuestas de otros dos algoritmos no supervisados frente a los mismos datos, concretamente K-Medoids y Hierarchical Clustering.

8.2. ANÁLISIS DEL COMPORTAMIENTO DE LAS TÉCNICAS NO SUPERVISADAS. ALGORITMO K-MEDOIDS.

En este apartado se muestran las precisiones logradas con el algoritmo no supervisado K-Medoids en la clasificación de los datos para cada uno de los casos estudiados. Se considerarán los cinco estados posibles del rodamiento. Los datos serán tratados, de nuevo, mediante el script “Script_Tratamiento_Datos” y la precisión será obtenida con el script “Script_Concordancia_Kmedoids”, ambos mostrados en el Anexo 2. Las precisiones resultantes se recogen en la Tabla 8.5.

Alimentación	Nivel de carga	Precisión (%)	Recall (%)	F1 (%)
RED	NC2	43.77	47.35	45.49
	NC1	31.85	48.16	38.34
WEG	NC2	37.9	48.57	42.57
	NC1	37.38	64.7	47.38
AB1	NC2	41.1	52.25	46

	NC1	39.41	57.75	46.85
AB2	NC2	44.87	65.1	53.12
	NC1	33.75	65.51	44.55
AB3	NC2	25.72	45.72	32.92
	NC1	61.86	74.5	67.6

AB4	NC2	51.26	66.33	57.83
	NC1	26.62	73.87	39.14

Tabla 8.5. Precisión, exhaustividad y F1 de K-Medoids para ensayos clasificados en cinco estados.

Los resultados que se obtienen con este algoritmo son similares, como se puede ver, que los conseguidos con K-Means. Por lo tanto, no del todo aceptables para este tipo de diagnósticos.

8.3. ANÁLISIS DEL COMPORTAMIENTO DE LAS TÉCNICAS NO SUPERVISADAS. HIERARCHICAL CLUSTERING.

En este tercer apartado se muestran las precisiones logradas con el algoritmo no supervisado Hierarchical Clustering en la clasificación de los datos para cada una de las posibilidades expuestas. Se considerarán los cinco estados posibles del rodamiento. Los datos serán tratados, una vez más, mediante el script “Script_Tratamiento_Datos” y la precisión será obtenida con el script “Script_Concordancia_Hierarchical_Clustering”, ambos mostrados en el Anexo 2.

Los resultados que se consiguen se recogen en la Tabla 8.6.

Alimentación	Nivel de carga	Precisión (%)	Recall (%)	F1 (%)
RED	NC2	22.53	70.20	34.11
	NC1	25.45	72.25	37.64
WEG	NC2	22.1	48.16	30.5
	NC1	23.91	81.84	37
AB1	NC2	26.67	67.75	38.27

	NC1	21.45	88.36	34.52
AB2	NC2	30.15	81.23	43.97
	NC1	22.42	72.25	34.22
AB3	NC2	20	82.3	32.18
	NC1	26.88	81	40.36

AB4	NC2	37.26	73.67	49.49
	NC1	23.42	82.65	36.5

Tabla 8.6. Precisión, exhaustividad y F1 de Hierarchical Clustering para ensayos clasificados en cinco estados.

Los resultados anteriores, en cuanto a la precisión, son peores a los obtenidos con los algoritmos estudiados en los apartados anteriores. Sin embargo, se ve que los valores de la exhaustividad son elevados, en torno al 80%, justificado por un menor número de pares de ensayos no diagnosticados con igual estado de manera equivocada. El parámetro F1, tiene valores inferiores, influenciado por el valor de las precisiones.

Tras el estudio llevado a cabo con los datos empleados, se puede concluir que la complejidad e importancia del motor de inducción en la industria y por lo tanto el papel crucial de un adecuado mantenimiento del mismo, suponen que este tipo de técnicas no supervisadas en este caso, como se ha demostrado en función de los resultados obtenidos, no son del todo adecuadas para ejercer un efectivo mantenimiento predictivo de los mismos.

8.4 COMPORTAMIENTO DE LAS TÉCNICAS NO SUPERVISADAS FRENTE A LA ALIMENTACIÓN DE RED CONSIDERANDO AMBOS NIVELES DE CARGA.

En este apartado se evaluarán las técnicas no supervisadas no haciendo distinción entre los dos niveles de carga posibles de los datos del motor, analizando así la respuesta frente a los diferentes tipos de alimentación. El número de estados de los rodamientos a considerar será de cinco. El objetivo es profundizar en el estudio y obtener más información sobre el comportamiento de estas técnicas. De antemano se puede pensar que al aumentar el número de datos los resultados puedan mejorar, sin embargo, hay

que tener en cuenta que también existirá diferencia entre los datos de un mismo estado, dificultando así su correcta clasificación.

Para el tratamiento de los datos, en esta ocasión, se emplea el script “Script_Tratamiento_Datos_NC2yNC1” y a la hora de obtener las diferentes precisiones se utiliza el script “Script_Concordancia_NC1yNC2”.

Las Tablas 8.7 y 8.8 recogen los resultados obtenidos con los algoritmos K-Means y Hierarchical Clustering para los diferentes casos ensayados.

Alimentación	K-Means		
	Precisión (%)	Recall (%)	F1(%)
RED	35.86	70.41	47.52
WEG	37.17	44.1	40.34
AB1	40.99	47.35	43.94
AB2	55	61.84	58.22
AB3	29.6	44.89	35.68
AB4	40.85	68.25	51.11

Tabla 8.7. Precisión, exhaustividad y F1 de K-Means sin distinción del nivel de carga.

Alimentación	Hierarchical Clustering		
	Precisión (%)	Recall (%)	F1(%)
RED	24.7	72.24	36.81
WEG	22.9	75.92	35.21
AB1	26.51	64.48	37.57
AB2	22.75	72.45	34.63
AB3	20.27	88.77	33.02
AB4	24	78.97	36.82

Tabla 8.8. Precisión, exhaustividad y F1 de Hierarchical Clustering sin distinción del nivel de carga.

Los resultados que se obtienen, como se observa, en el caso del algoritmo K-Means son semejantes que los logrados al diferenciar los dos niveles de carga, aunque un poco peores en la mayoría de los casos. Esto puede deberse, como ya se ha comentado, al aumento de la discrepancia de los datos característicos de un mismo estado de los rodamientos.

En el caso de Hierarchical Clustering se comprueba que ocurre algo similar, consiguiendo peores datos respecto a la separación de niveles de carga. Además, las precisiones logradas son peores que en el caso de utilizar K-Means, las exhaustividades mayores y el factor F1 menor, al igual que ocurría en el caso de diferenciar los dos niveles de carga.

8.5 COMPORTAMIENTO DE LAS TÉCNICAS NO SUPERVISADAS FRENTE A LA ALIMENTACIÓN A 50 HZ Y NIVEL DE CARGA NOMINAL.

En este caso se propone el análisis de los datos teniendo en cuenta tan solo aquellos obtenidos cuando la frecuencia de la onda de alimentación era de 50 Hz y el nivel de carga era el nominal. Es decir, los casos de alimentación RED, WEG y AB1, todos con nivel de carga nominal. Se unirán, por lo tanto, todos los casos en los que la clasificación de los datos, a priori, es más sencilla.

El tratamiento de los datos se logra con el script "Script_Tratamiento_Datos_50HzNC2". A la hora de obtener las diferentes precisiones se utiliza el script "Script_Concordancia" y el script "Script_Concordancia_Hierarchical_Clustering",

En el caso de K-Means, la precisión obtenida es de 37.45%, la exhaustividad del 63% y F1 del 46.97%, siendo la matriz de confusión la siguiente:

		AGRUPACIÓN GENERADA	
		1	0
AGRUPACIÓN REAL	1	TP=309	FN=181
	0	FP=516	TN=1409

Figura 8.37. Matriz de confusión y parámetros asociados de K-Means en los casos RED_NC2, WEG_NC2 y AB1_NC2.

Por su parte, la precisión lograda con Hierarchical Clustering es de 22.53%, la exhaustividad del 70.20% y F1 del 34.11%, siendo la matriz de confusión la mostrada a continuación:

		AGRUPACIÓN GENERADA	
		1	0
AGRUPACIÓN REAL	1	TP=344	FN=146
	0	FP=1183	TN=742

Figura 8.38. Matriz de confusión y parámetros asociados de Hierarchical Clustering en los casos RED_NC2, WEG_NC2 y AB1_NC2.

Los resultados obtenidos con K-Means son semejantes, un poco inferiores de manera general a los logrados en el análisis por separado de las distintas alimentaciones, debido a la pérdida de semejanza de datos que presentan igual estado. El comportamiento del segundo algoritmo no varía demasiado con esta configuración de datos de entrada, presentando baja precisión y alta exhaustividad.

Los resultados de los dos apartados anteriores, en cualquier caso, continúan siendo insuficientes para la exigencia que requiere al diagnóstico del estado de los motores de inducción.

8.6. ANÁLISIS DEL COMPORTAMIENTO DE LAS TÉCNICAS SUPERVISADAS.

En este apartado del capítulo 8 se va a evaluar el comportamiento de las técnicas de Machine Learning supervisadas, de manera similar a como se hizo en el apartado 8.1 para el caso de las no supervisadas. Para realizar dicha tarea se utilizará la App “Classification Learner” que incluye MATLAB y que permite obtener el algoritmo, dentro de los supervisados, que mejor clasifique los datos de entrada. Para ello, la aplicación nombrada emplea la técnica conocida como “Cross-Validation”, la cual consiste en utilizar parte de los datos de entrada para el entrenamiento del algoritmo en cuestión y el resto de los datos, una vez entrenado el algoritmo, para ejercer de entradas al mismo y conocer así la precisión que este presenta en función de los resultados obtenidos, es decir, para la validación del algoritmo.

El número de estados a tener en cuenta en este estudio serán, en primer lugar, los cinco estados iniciales del rodamiento, desde sano hasta destruido completamente. Posterior al estudio anterior se considerarán dos estados, rodamiento sano y cualquier presencia de fallo, mostrando únicamente las precisiones obtenidas. Hay que tener en cuenta que, en esta ocasión, por la naturaleza de las técnicas a emplear, es necesario introducir junto con los valores de las amplitudes de cada ensayo el estado de los mismos.

El tratamiento de los datos para que estos sean compatibles con las App se llevará a cabo de igual modo que en ocasiones anteriores, a través del script “Script_Tratamiento_Datos”, empleando esta vez para la obtención de resultados la variable “Datos_Tabla”, al incluir esta el estado de cada ensayo. Será dicha variable la que se empleará en la App anteriormente indicada para el estudio a desarrollar.

De este modo, se irán mostrando las respuestas conseguidas a través de Classification Learner para cada tipo de alimentación y nivel de carga. Dichas respuestas, en este primer estudio, será el algoritmo que presente mayor precisión a la hora de la clasificación y la matriz de confusión resultante, indicándose en esta el número de ensayos que el algoritmo establece con cierto estado y el estado al que realmente pertenecen.

El algoritmo elegido en cada caso se podría exportar y emplearse para el diagnóstico del estado de otros motores de inducción introduciendo los valores de la corriente consumida, pero este no será el caso en el presente TFG.

8.6.1. COMPORTAMIENTO DEL ALGORITMO SUPERVISADO FRENTE A CINCO ESTADOS DE LOS RODAMIENTOS.

MOTOR ALIMENTADO DIRECTAMENTE DE RED, CON NIVEL DE CARGA NOMINAL.

En este primer caso, el algoritmo que alcanza la mayor precisión a la hora de establecer una clasificación de los estados del rodamiento es “Linear Discriminant”, siendo esta del 94.3%. La matriz de confusión se muestra a continuación en la Figura 8.39.

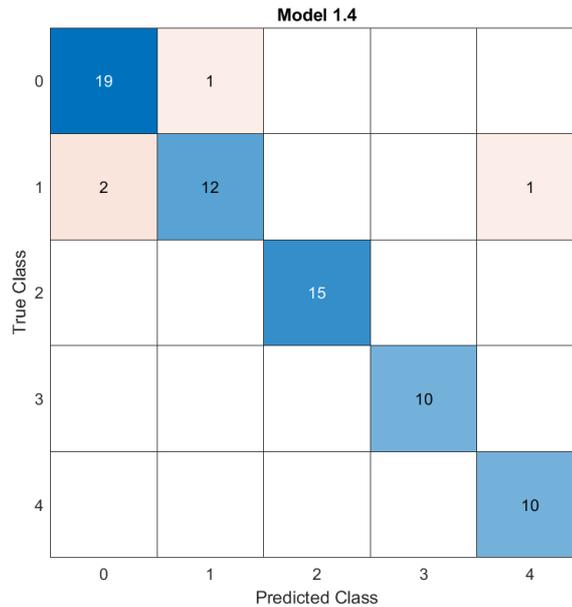


Figura 8.39. Matriz de confusión de los datos RED_NC2 para técnicas supervisadas.

En primer lugar, lo que destaca es la elevada precisión con la que el algoritmo clasifica los datos, cercana al 100%. Observando la matriz de confusión, se ve que, respecto a los ensayos sanos, tan sólo uno lo clasifica de manera errónea, haciéndolo como fallo leve. Para el caso de fallos leves, dos de ellos los clasifica como estado sano y uno como estado totalmente destruido, constituyendo por lo tanto el error más grave que cometería dicho algoritmo. En cuanto al resto de fallos, la precisión es del 100%, algo muy interesante a la hora de conocer el estado exacto del motor frente a un fallo y actuar en consecuencia de la mejor manera.

MOTOR ALIMENTADO DIRECTAMENTE DE RED, CON NIVEL DE CARGA BAJA.

Para este tipo de alimentación y nivel de carga, el algoritmo que alcanza la mayor precisión a la hora de establecer una clasificación de los estados del rodamiento es “Fine KNN”, un tipo de algoritmo del grupo “k-Nearest Neighbors”, siendo esta del 97.1%. La matriz de confusión se muestra a continuación en la Figura 8.40.

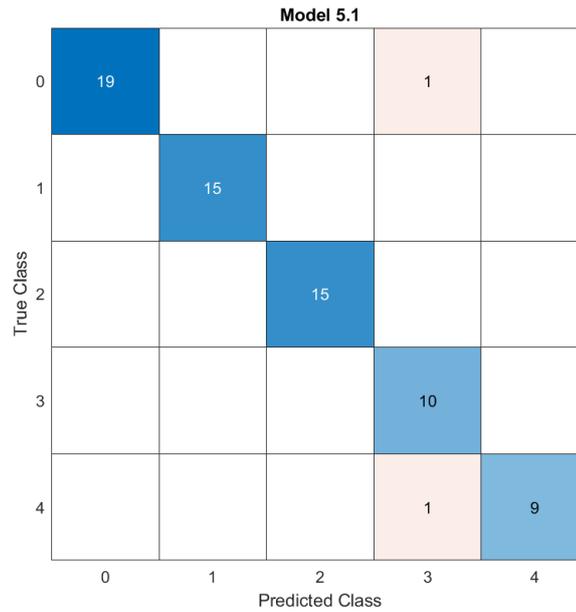


Figura 8.40. Matriz de confusión de los datos RED_NC1 para técnicas supervisadas.

MOTOR ALIMENTADO MEDIANTE UN VARIADOR DE FRECUENCIA WEG CON NIVEL DE CARGA NOMINAL.

En esta ocasión hay tres algoritmos que obtienen igual precisión, del 84.3%. Dichos algoritmos son “Fine KKN”, “Narrow Neural Network” y “Medium Neural Network”. La matriz de confusión obtenida mediante el algoritmo “Fine KKN” se muestra a continuación en la Figura 8.41.

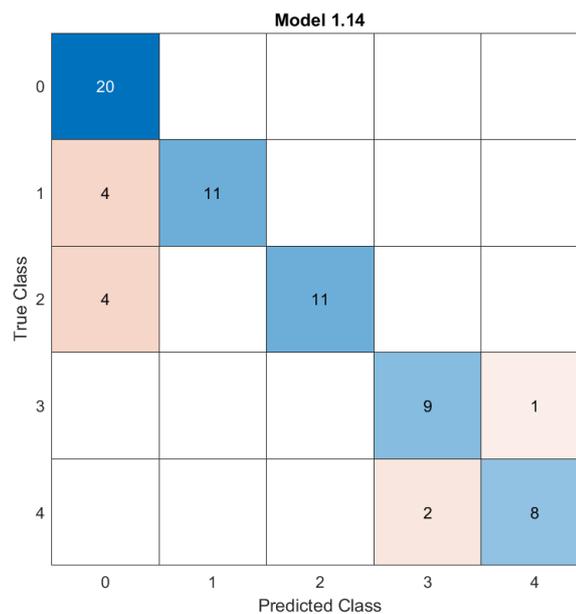


Figura 8.41. Matriz de confusión de los datos WEG_NC2 para técnicas supervisadas.

MOTOR ALIMENTADO MEDIANTE UN VARIADOR DE FRECUENCIA WEG CON NIVEL DE CARGA BAJO.

El algoritmo que alcanza la mayor precisión es “Medium Neural Network”, siendo esta del 77.1%. La matriz de confusión se muestra a continuación en la Figura 8.42.

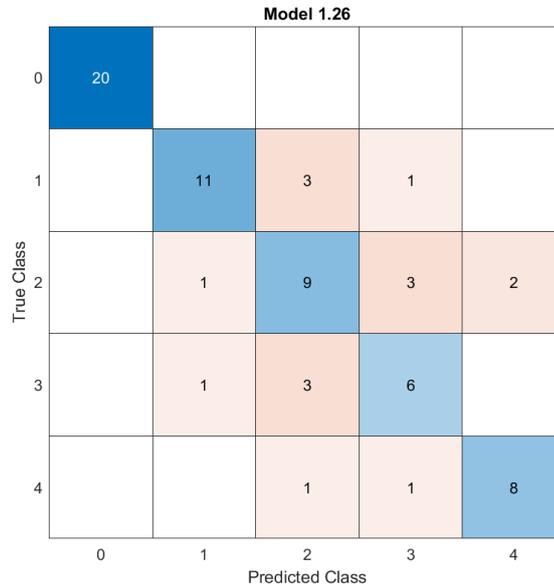


Figura 8.42. Matriz de confusión de los datos WEG_NC1 para técnicas supervisadas.

MOTOR ALIMENTADO MEDIANTE UN VARIADOR DE FRECUENCIA AB1 CON NIVEL DE CARGA NOMINAL.

El algoritmo que alcanza la mayor precisión es “Linear Discriminant”, siendo del 97.1%. La matriz de confusión se muestra a continuación en la Figura 8.43.

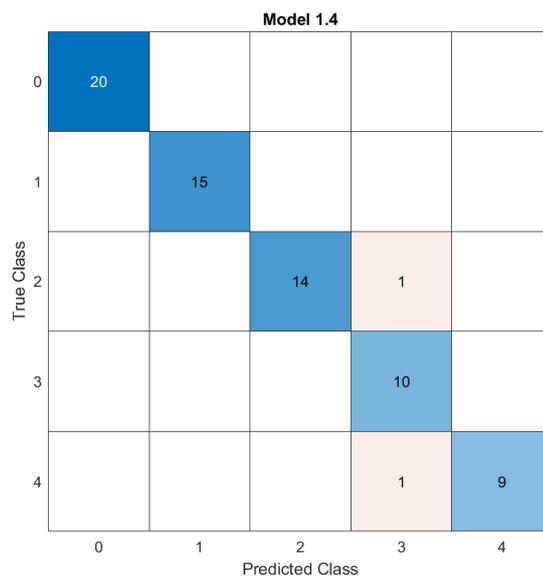


Figura 8.43. Matriz de confusión de los datos AB1_NC2 para técnicas supervisadas.

MOTOR ALIMENTADO MEDIANTE UN VARIADOR DE FRECUENCIA AB1 CON NIVEL DE CARGA BAJO.

El algoritmo que alcanza la mayor precisión es “Quadratic SVM”, siendo esta del 85.7%. La matriz de confusión se muestra a continuación en la Figura 8.44.

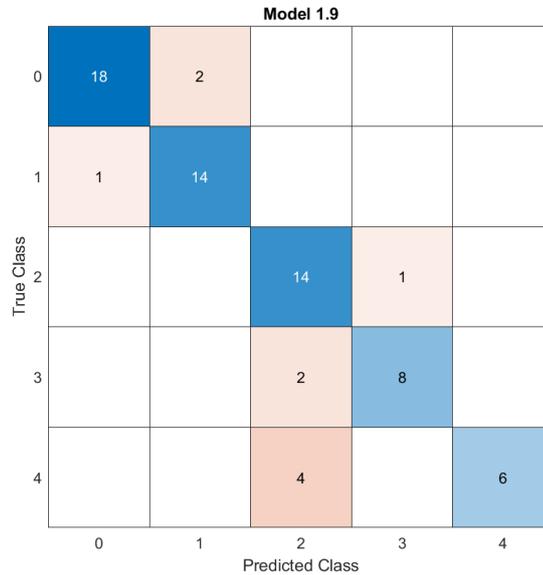


Figura 8.44. Matriz de confusión de los datos AB1_NC1 para técnicas supervisadas.

MOTOR ALIMENTADO MEDIANTE UN VARIADOR DE FRECUENCIA AB2 CON NIVEL DE CARGA NOMINAL.

El algoritmo que alcanza la mayor precisión es “Wide Neutral Network”, siendo esta del 97.1%. La matriz de confusión se muestra a continuación en la Figura 8.45.

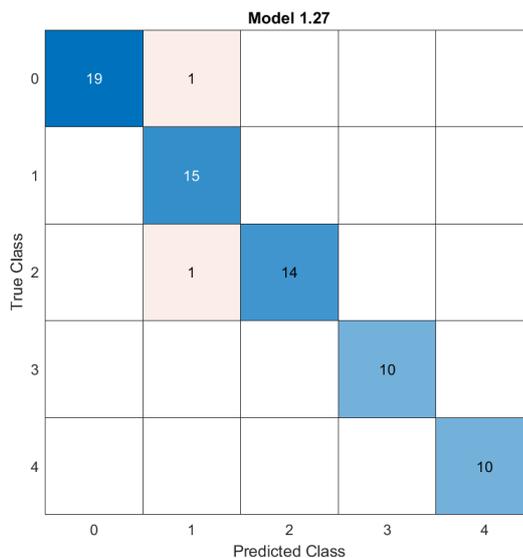


Figura 8.45. Matriz de confusión de los datos AB2_NC2 para técnicas supervisadas.

MOTOR ALIMENTADO MEDIANTE UN VARIADOR DE FRECUENCIA AB2 CON NIVEL DE CARGA BAJO.

Para esta configuración, los algoritmos que alcanza la mayor precisión son “Linear SVM” y “SVM Kernel”, siendo esta del 75.7%. La matriz de confusión obtenida con el primero de ellos se muestra a continuación en la Figura 8.46.

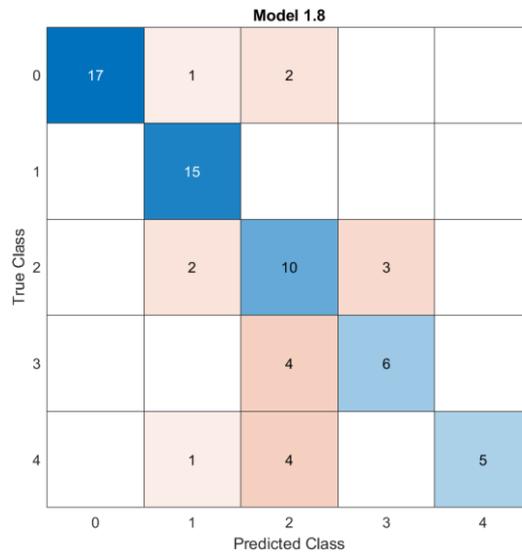


Figura 8.46. Matriz de confusión de los datos AB2_NC1 para técnicas supervisadas.

MOTOR ALIMENTADO MEDIANTE UN VARIADOR DE FRECUENCIA AB3 CON NIVEL DE CARGA NOMINAL.

El algoritmo que alcanza la mayor precisión es “Fine KNN”, siendo esta del 65.7%. La matriz de confusión se muestra a continuación en la Figura 8.47.

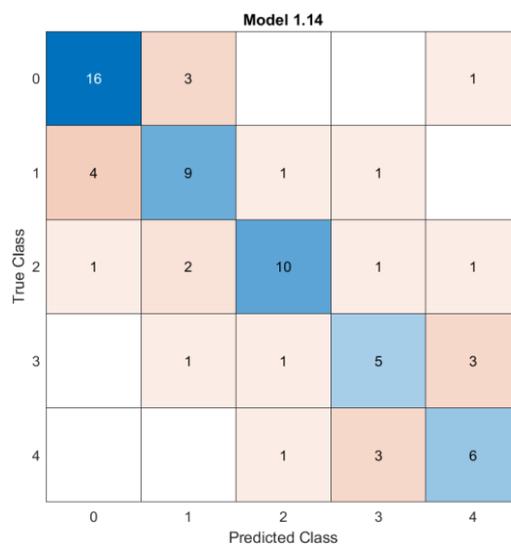


Figura 8.47. Matriz de confusión de los datos AB3_NC2 para técnicas supervisadas.

MOTOR ALIMENTADO MEDIANTE UN VARIADOR DE FRECUENCIA AB3 CON NIVEL DE CARGA BAJO.

El algoritmo que alcanza la mayor precisión es “Subspace KNN”, siendo esta del 100%. La matriz de confusión se muestra a continuación en la Figura 8.48.

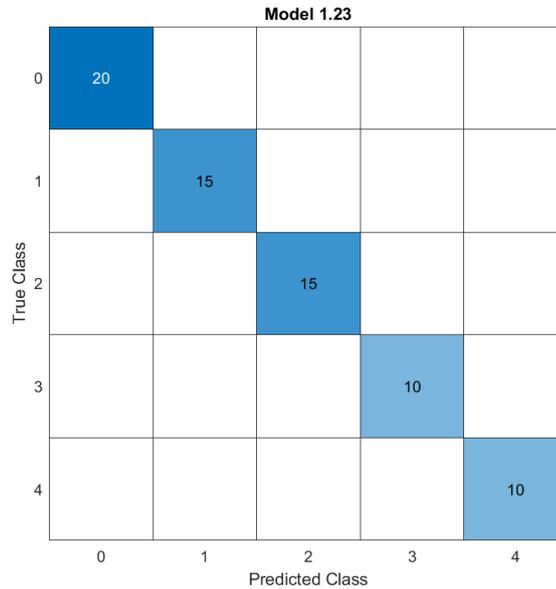


Figura 8.48. Matriz de confusión de los datos AB3_NC1 para técnicas supervisadas.

MOTOR ALIMENTADO MEDIANTE UN VARIADOR DE FRECUENCIA AB4 CON NIVEL DE CARGA NOMINAL.

El algoritmo que alcanza la mayor precisión es “Fine KNN”, siendo esta del 95.7%. La matriz de confusión se muestra a continuación en la Figura 8.49.

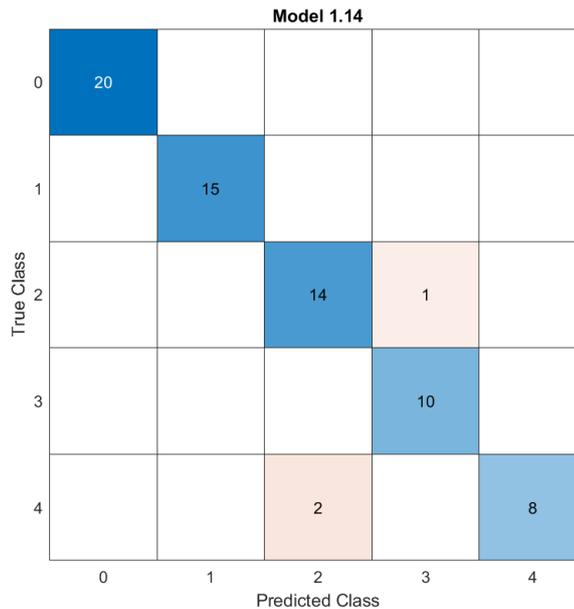


Figura 8.49. Matriz de confusión de los datos AB4_NC2 para técnicas supervisadas.

MOTOR ALIMENTADO MEDIANTE UN VARIADOR DE FRECUENCIA AB4 CON NIVEL DE CARGA BAJO.

El algoritmo que alcanza la mayor precisión es “Wide Neural Network”, siendo del 90%. La matriz de confusión se muestra a continuación en la Figura 8.50.

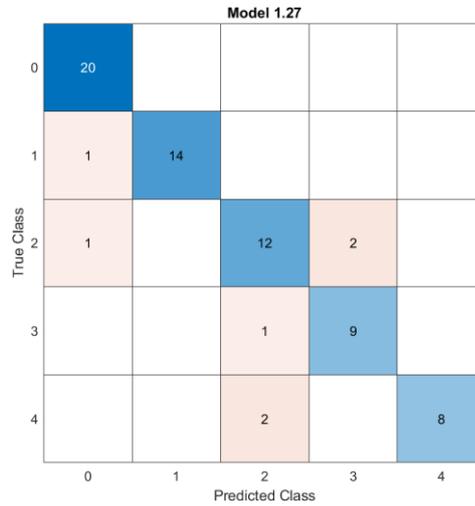


Figura 8.50. Matriz de confusión de los datos AB4_NC1 para técnicas supervisadas.

En la Tabla 8.9 se reúnen las precisiones que presentan los diferentes algoritmos anteriores frente a la clasificación de los datos de estudio en cada una de las configuraciones establecidas.

Alimentación	Nivel de carga	Precisión (%)
RED	NC2	94.3
	NC1	97.1
WEG	NC2	84.3
	NC1	77.1

AB1	NC2	97.1
	NC1	85.7
AB2	NC2	97.1
	NC1	75.7
AB3	NC2	65.7
	NC1	100
AB4	NC2	95.7
	NC1	90

Tabla 8.9. Precisiones de técnicas supervisadas para ensayos clasificados en cinco estados.

Lo primero que se puede ver es que las precisiones logradas son mucho mejores que en el caso de técnicas no supervisadas. Esto refleja que este tipo de técnicas son más apropiadas para este tipo de diagnósticos. Además, de manera general, las precisiones son mayores cuando el nivel de carga es

nominal, siendo destacable que esto no se cumple en el caso de alimentación directa de la red. Si se comparan los dos tipos de convertidores, se consiguen mejores precisiones mediante el convertidor Allen Bradley. Finalmente, comparando los casos AB1, AB2 y AB3, de manera general, se ve que los resultados son mejores si la frecuencia de alimentación es de 50 Hz, es decir el caso AB1.

8.6.2. COMPORTAMIENTO DEL ALGORITMO FRENTE A DOS ESTADOS DE LOS RODAMIENTOS.

Las precisiones obtenidas por el algoritmo que mejor se adapta a los datos de entrada en cada caso se muestra en la Tabla 8.10, incluyendo las logradas en el apartado anterior.

Alimentación	Nivel de carga	Precisión 2 estados (%)	Precisión 5 estados (%)
RED	NC2	97.1	94.3
	NC1	100	97.1
WEG	NC2	81.4	84.3

	NC1	97	77.1
AB1	NC2	100	97.1
	NC1	97.1	85.7
AB2	NC2	98.6	97.1
	NC1	97.1	75.7
AB3	NC2	92.9	65.7

	NC1	100	100
AB4	NC2	98.6	95.7
	NC1	88.6	90

Tabla 8.10. Precisiones de técnicas supervisadas para ensayos clasificados en dos y cinco estados.

Se puede comprobar, de manera general, que los resultados son mejores cuando se establecen tan solo dos estados de los rodamientos. Esto se debe, como ya se ha comentado en otros apartados, a la mayor discrepancia entre datos y mayor facilidad por lo tanto de clasificarlos.

CAPÍTULO 9.

CONCLUSIONES.

En este noveno capítulo del presente trabajo se expondrán las conclusiones obtenidas tras los análisis de las respuestas de técnicas supervisadas y no supervisadas para llevar a cabo tareas de mantenimiento predictivo aplicado a motores de inducción, concretamente al estado de sus rodamientos. Se ha de tener presente que dichas respuestas son la precisión, el valor de la exhaustividad y el de F1, en el caso de las no supervisadas y la precisión en el caso de las supervisadas. Dichos valores serán el resultado de la clasificación de los datos indicativos del estado de los rodamientos en cada caso.

Dichas conclusiones, en función de los ensayos realizados, se recopilan a continuación:

- Se obtienen mejores resultados, en ambos tipos de técnicas, a la hora de clasificar los datos cuando el motor se alimenta directamente desde la red que en el resto de posibles alimentaciones. Esto se debe a que los convertidores introducen una serie de nuevos armónicos al espectro, provocando nuevos problemas y complicando así la clasificación. Estos últimos se mezclan con los armónicos indicativos de fallos en los rodamientos, dificultando la obtención de las frecuencias en el espectro.
- Respecto a los dos niveles de carga del motor posibles, carga baja y carga nominal, se logran mejores resultados cuando el nivel de esta es el nominal. Cuando esto sucede, las amplitudes en el espectro de la corriente son mayores y, por lo tanto, existirá mayor discrepancia entre datos, facilitando así la identificación de fallos.
- En cuanto a la frecuencia de la onda de alimentación que sale de los convertidores, se consiguen mayores precisiones de manera general cuando esta es de 50 Hz que en los casos de 25 Hz y 75 Hz.
- Respecto a la frecuencia de conmutación que presentan los convertidores de frecuencia, se observa que los resultados en las técnicas supervisadas son mejores cuando dicho parámetro tiene un valor de 4 kHz frente a 5 kHz. Esto se justifica porque al aumentar la

frecuencia de conmutación, aumentan los armónicos introducidos, complicando así la clasificación. En las técnicas no supervisadas, los resultados logrados no permiten un diagnóstico claro de este aspecto.

- Como ya se adelantó, las técnicas supervisadas ofrecen unos resultados mucho mejores para este tipo de diagnósticos que las no supervisadas, siendo los obtenidos con estas últimas insuficientes para un diagnóstico preciso.
- Dentro del estudio de las técnicas supervisadas, se observan mejores comportamientos de las mismas cuando el número de estados de los rodamientos a tener en cuenta es de 2 que en el caso de considerar 5 estados. Al introducir una mayor cantidad de estados, la discrepancia entre los datos disminuye y su clasificación se complica. En el caso de tener en cuenta datos sanos y cualquier presencia de fallo, la discrepancia, lógicamente, será mayor entre dichos grupos de datos.
- De igual manera que en las técnicas supervisadas, en el caso de las no supervisadas los resultados logrados son mejores cuando se consideran tan solo dos estados de los rodamientos que cinco.
- Para el caso de las técnicas no supervisadas, se observan, como se esperaba, diferencias entre las precisiones, exhaustividades y el factor F1 logrados al considerar dos estados de los rodamientos y tres estados, siendo mejores en el primer caso.
- Se logran peores resultados en el caso de no diferenciar los dos niveles de carga posibles en el diagnóstico de las técnicas no supervisadas. Esto se justifica por el aumento de discrepancia entre los datos de los ensayos que presentan igual estado para cada nivel de carga.
- En el caso de unir todos los datos de los ensayos que presenten una frecuencia de alimentación de 50 Hz y un nivel de carga nominal, los resultados no difieren demasiado de los conseguidos en los análisis por separado, siendo un poco peores al introducir, de nuevo, mayor diferencia entre datos con igual estado.
- En cuanto a la comparativa de los algoritmos no supervisados empleados, no se aprecian grandes diferencias entre K-Means y K-

Meodois, debido a su funcionamiento semejante. Entre K-Means y Hierarchical Clustering, se ve que los resultados son mejores con K-Means en cuanto al factor F1, sabiendo además que Hierarchical Clustering no responde adecuadamente para grandes conjuntos de datos.

- Destacan los altos valores de exhaustividad en los algoritmos no supervisados respecto a los valores de la precisión, especialmente en el caso de Hierarchical Clustering. Esto se debe al elevado valor del parámetro FP, es decir, los algoritmos tienden a asignar más pares de ensayos en el mismo grupo de los que realmente existen. Además, es notable la gran capacidad de este tipo de técnicas a la hora de detectar pares de ensayos que no pertenecen a igual grupo, reflejándose en altos valores del parámetro TN.
- Empleando los datos indicativos del estado de los rodamientos, con los que se realizan los estudios del presente trabajo, tanto a las técnicas supervisadas como a las no supervisadas, se llega a la conclusión de que estas segundas técnicas no son del todo adecuadas para este tipo de diagnósticos. La complejidad e importancia que conlleva el mantenimiento de los motores de inducción suponen que las precisiones a la hora de establecer el estado de los rodamientos en función de la corriente del estátor, logradas con estas técnicas, sean insuficientes para garantizar fiabilidad.
- En cuanto a las técnicas supervisadas, como se ha podido comprobar, sí son adecuadas para estos diagnósticos, logrando altas precisiones en la clasificación de los datos. Justificando de esta manera su habitual utilización para el mantenimiento de motores de inducción.

CAPÍTULO 10.

BIBLIOGRAFÍA.

En este capítulo se mostrarán las referencias bibliográficas empleadas para el desarrollo de este TFG, siguiendo la normativa APA para la realización de las mismas.

LIBROS

[1] Fraile, J. (2003). Máquinas Eléctricas. (5ª ed). Madrid. McGRAW-HILL.

[15] Duque, O. Pérez, M. (2005). Motores de inducción. Técnicas de mantenimiento predictivo. Madrid-Valladolid.

TESIS DOCTORALES

[2] Martín, I. (2017). Metodología de diagnóstico de motores de inducción alimentados por convertidor para la detección de fallos incipientes, basada en conjuntos pequeños de datos y clases desequilibradas. [Tesis de doctorado]. Universidad de Valladolid. Universidad de Guanajuato. España. México.

APUNTES DE ASIGNATURAS CURSADAS

[3] Serrano, J.A, San Martín, M.L y Parra, E.P. (curso 2019/2020). Máquinas rotativas de corriente alterna. Máquinas eléctricas I. Grado en Ingeniería Eléctrica. Universidad de Valladolid.

[14] Duque, O. (curso 2020/2021). Fallo en motores de inducción. Mantenimiento de instalaciones eléctricas. Grado en Ingeniería Eléctrica. Universidad de Valladolid.

[18] Duque, O. (curso 2020/2021). Mantenimiento industrial. Organización y planificación del mantenimiento. Mantenimiento de instalaciones eléctricas. Grado en Ingeniería Eléctrica. Universidad de Valladolid.

[19] Duque, O. (curso 2020/2021). Mantenimiento predictivo de motores eléctricos. Mantenimiento de instalaciones eléctricas. Grado en Ingeniería Eléctrica. Universidad de Valladolid.

PÁGINAS WEB

[4] Ley de la fuerza de Lorenz y la segunda ley de Laplace. (s.f.) <http://rsefalicante.umh.es/TemasElectromagnetismo/Electromagnetismo02.htm> (consultado en mayo de 2021)

[5] Potencia Electromecánica. (s.f.). Motores asíncronos de inducción. <https://www.potenciaelectromecanica.com/motores-asincronos-de-induccion/> (consultado en mayo de 2021)

[6] Wikipedia. (2021). https://es.wikipedia.org/wiki/K_vecinos_m%C3%A1s_pr%C3%B3ximos (consultado el 23 de septiembre 2021)

[7] Estrategias de Trading. (s.f.). K-Means Clustering: Agrupamiento con Minería de datos. <https://estrategiastrading.com/k-means/> (consultado el 22 de septiembre de 2021)

[8] Estrategias de Trading. (s.f.). Algoritmos de Data Mining para agrupar datos - Clustering Jerárquico. [https://estrategiastrading.com/clustering-jerarquico/#:~:text=El%20Clustering%20Jer%C3%A1rquico%20\(agrupamiento%20jer%C3%A1rquico,datos%20se%20les%20llama%20cl%C3%BAsters\).](https://estrategiastrading.com/clustering-jerarquico/#:~:text=El%20Clustering%20Jer%C3%A1rquico%20(agrupamiento%20jer%C3%A1rquico,datos%20se%20les%20llama%20cl%C3%BAsters).) (consultado el 22 de septiembre de 2021).

[13] BirtLH. (s.f.). Motor de doble jaula de ardilla. https://ikastaroak.birt.eus/edu/argitalpen/backupa/20200331/1920k/es/IEA/ME/ME06/es_IEA_ME06_Contenidos/website_33_motor_de_doble_jaula_de_ardilla.html (Consultado el 24 de septiembre de 2021).

[16] Cecacanarias. (2018). ¿Por qué se quema un motor eléctrico? <http://www.cecacanarias.com/quema-bobinado-motor-electrico/>

MANUALES

[9] MATLAB. Machine Learning with MATLAB. (2020).

CATÁLOGOS

[10] SKF. (2016). Rodamientos y sellos en motores eléctricos y generadores. https://www.skf.com/binaries/pub42/Images/0901d19680523351-13459-ES-Rolling-bearings-and-seals-in-electrical-motors-and-generators_tcm_42-134586.pdf

[11] Weg. (2020). W22: Motor eléctrico monofásico. <https://static.weg.net/medias/downloadcenter/h35/h2b/WEG-w22-motor-electrico-monofasico-50070884-brochure-spanish-web.pdf>

[12] Weg. (s.f). W50 - TEFC Uso General (Hierro Gris) https://www.weg.net/catalog/weg/ES/es/Motores-El%C3%A9ctricos/Motores-de-Inducci%C3%B3n---Media-Alta-Tensi%C3%B3n/Motores-de-Inducci%C3%B3n-Trif%C3%A1sico/Motores-IEC/W50---TEFC-Uso-General-%28Hierro-Gris%29/W50---TEFC-Uso-General-%28Hierro-Gris%29/p/MKT_WMO_TEXT_IMAGE_HV_NEMA_3PHASE_TEFC_W50_IEC

[17] SKF (2017). Daño de rodamientos y análisis de fallas. https://www.skf.com/binaries/pub201/Images/0901d196807d76f8-Bearing-failures---14219_2-ES-AR_tcm_201-297619.pdf

ARTÍCULOS.

[20] Fontes, W., Moriñigo, D., Duque, O., Nunes, I., Goedel, A., Cunha, R.H. (2020). Estimation of Bearing Fault Severity in Line-Connected and Inverter-Fed Three-Phase Induction Motors. *Energies*.

[21] Jain, P. *Unsupervised Machine Learning: Validation Techniques*. Guavus.

ANEXO 1

INSTRUMENTOS PARA LA REALIZACIÓN DE LOS ENSAYOS Y LA TOMA DE DATOS.

En el Anexo 1 se van a mostrar los diferentes dispositivos empleados por el Departamento de Ingeniería Eléctrica de la Universidad de Valladolid para la realización de los ensayos del motor de inducción y la toma de datos. De esta manera, se consiguen los datos necesarios de los diferentes modos de alimentación y niveles de carga.

A1.1. MOTOR DE INDUCCIÓN.

El motor utilizado pertenece a la marca SIEMENS, siendo alterado adecuadamente para reproducir los diferentes estados de los rodamientos. Los parámetros nominales del motor se recogen en la Tabla A1.1, mostrándose una imagen del mismo en la Figura A1.1.

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
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

Tabla A1.1. Parámetros nominales del motor empleado.

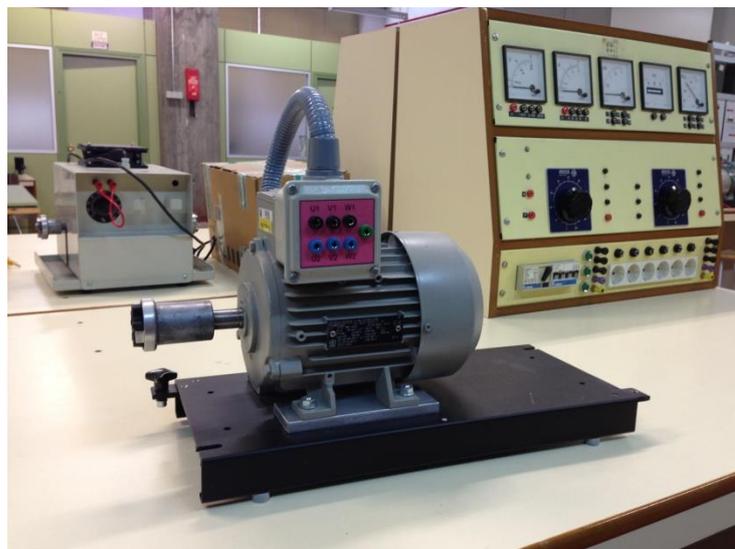


Figura A1.1. Motor empleado de la marca SIEMENS.

A1.2. VARIADORES DE FRECUENCIA

Los dos variadores de frecuencia empleados en los ensayos son los mostrados a continuación.

Variador CFW-11 Vectrue inverter de WEG:

Sus características se muestran en la Tabla A1.2 y una imagen del mismo, en la Figura A1.2.

Potencia nominal	2,2 kW
Tensión y frecuencia de alimentación	3x380 - 480 V (50/60 Hz)
Tensión de salida	0 - Tensión de Entrada V
Corriente nominal	3.5 A
Frecuencia de salida	0,1 - 300 Hz
Corriente máx. de salida en continuo	3.5 A
Sobrecarga temporal (60 seg)	5.25 A
Denominación	EUCFW110003T40FAZ
Número de serie	1018525712
Índice de protección	IP20

Tabla A1.2. Parámetros nominales del variador de frecuencia WEG CFW-11.



Figura A1.2. Variador de frecuencia WEG CFW-11.

Variador PowerFlex 40 de Allen-Bradley.

Sus parámetros nominales se muestran en la Tabla A1.3 y una imagen del mismo, en la Figura A1.3.

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

Tabla A1.3. Parámetros nominales del variador de frecuencia Allen-Bradley PowerFlex 40.



Figura A1.3. Variador de frecuencia Allen-Bradley PowerFlex 40.

A.1.3. FRENO DE POLVO MAGNÉTICO Y UNIDAD DE CONTROL.

Para simular los dos niveles de carga empleados en los ensayos se ha utilizado un freno de polvo magnético de la marca Lucas-Nülle. El par resistente que ejerce dicho freno se establece a través de una unidad de control, también de la marca Lucas-Nülle, asociada al mismo.

La Tabla A1.4 recoge las características del freno de polvo magnético, la Tabla A1.5 las de la unidad de control y la Figura A1.4 muestra a ambos dispositivos conectados.

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

Tabla A1.4. Características del freno de polvo magnético de Lucas-Nülle.

Tensión y frecuencia de alimentación	230 V 50 Hz
Denominación	S0 3213-7S

Tabla A1.5. Características de la unidad de control de Lucas-Nülle.



Figura A1.4. Freno de polvo magnético y unidad de control de Lucas-Nülle.

A1.4. TRANSDUCTORES DE CORRIENTE.

Para la captura de la corriente de alimentación del motor se emplearon dos transductores de corriente de Honeywell y uno de LEM, todos basados en el efecto Hall.

TRANSDUCTOR DE CORRIENTE HONEYWELL.

Presenta las siguientes características:

- 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 A1.5. Transductor de corriente Honeywell.

TRANSDUCTOR DE CORRIENTE LEM

Presenta las siguientes características:

- 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

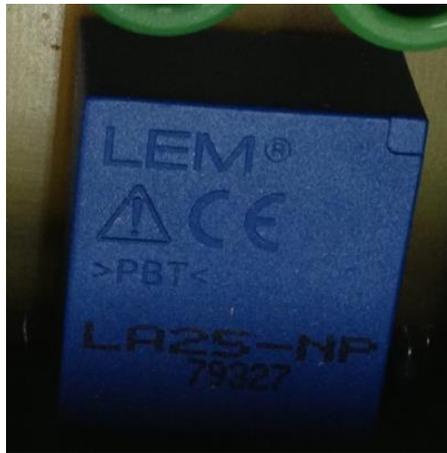


Figura A1.6. Transductor de corriente LEM.

A1.5. SISTEMA DE ADQUISICIÓN DE DATOS.

El sistema para la adquisición de los datos se basa en una plataforma de National Instruments, formada por lo siguiente:

Chasis compacto NI cDAQ-9174.

Este permite la conexión de hasta 4 módulos E/S y sus características son:

- 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 de adquisición: NI 9215.

Las características son:

- 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

La Figura A1.7 muestra el sistema de adquisición de datos empleado.



Figura A1.7. Sistema de adquisición de datos de National Instruments.

El sistema de adquisición de datos va conectado vía USB 2.0 a un PC portátil de la marca HP, modelo 6717s, con un procesador AMD Turion 64 con 4 GB de memoria RAM. En cuanto al sistema operativo, es Windows 7 Professional de 64 bits. El software encargado de mostrar los resultados de los ensayos es MATLAB versión R2010, guardando los mismos en archivos punto “mat”.



Figura A1.8. PC portátil del sistema de adquisición de datos.

ANEXO 2.

SCRIPTS EMPLEADOS.

A2.1. SCRIPT_TRATAMIENTO_DATOS.

% TRATAMIENTO DE DATOS PARA EL DIAGNÓSTICO DEL ESTADO DE LOS RODAMIENTOS DE UN MOTOR DE INDUCCIÓN.

```
clear all; clc
tic %Inicializa el tiempo transcurrido

%La clasificación multiclase de los datos será:
% y = 0 ==> Rodamiento sano
% y = 1 ==> Fallo leve
% y = 2 ==> Fallo moderado
% y = 3 ==> Fallo Grave
% y = 4 ==> Fallo muy grave

% Vector de resultados, recogiendo los estados del rodamiento.
y = zeros(70,1);
y(1:20) = 0;
y(21:35) = 1;
y(36:50) = 2;
y(51:60) = 3;
y(61:70) = 4;

% Se define el nombre de las matrices que tendremos que cargar en cada
caso
% Alimentación = {'Datos_RED_NC2';'Datos_RED_NC1';'Datos_WEG_NC2';
% 'Datos_WEG_NC1'; 'Datos_AB1_NC2';'Datos_AB1_NC1';'Datos_AB2_NC2';
%
'Datos_AB2_NC1';'Datos_AB3_NC2';'Datos_AB3_NC1';'Datos_AB4_NC2';'Dato
s_AB4_NC1'};

Alimentacion = {'Datos_AB4_NC2'};
niveles = {'_E0';'_E1';'_E2';'_E3';'_E4'}; % Estados reales del rodamiento.
fallos = {'BPFI';'BPFO';'BFTF';'BSF'}; %Las frecuencias características de fallo.

% Se crea un bucle para recorrer las variables de inicio a fin.
for l=1:length(Alimentacion)

    name = Alimentacion{l};
```

```
load(name);
name_xlx = strcat(name, '_Scores', '.xlsx');
Xdatos = zeros(0,0);
% Se crea otro bucle para ir recorriendo las diferentes frecuencias
% características.
for g=1: length (fallos)

% Se cargan todos los datos en una matriz de datos.
Xtemp = zeros(0,0);
% Se crea otro bucle para recorrer los diferentes estados.
for a=1:length(niveles)
    data= eval(['fallos{g},niveles{a}']);
    data = data(3:end,:);
    Xtemp = [Xtemp;data];
    clear data
end
% Con estos tres bucles se consigue ir cargando los datos de cada
variable en función del tipo de alimentación, la carga, la frecuencia de fallo y
el estado del rodamiento.

% Se va introduciendo en Xdatos los datos de cada variable.
Xdatos = [Xdatos Xtemp];
clear Xtemp;

end
% Se interpola para identificar frecuencias donde la toma de datos del
motor de inducción ha sido defectuosamente tomada:
Xdatos = interpolar(Xdatos);

% Se preparan los datos eliminando las columnas con valores NaN (valores
vacíos).
[m, n] = size(Xdatos);
k = ~isnan(Xdatos());
sum_noNaN = sum(k,1);
indNaN = find(sum_noNaN<m);
Xdatos(:, indNaN) = [];
clear k sum_noNaN indNaN;

% Finalmente, se crean la variable en forma de tabla que contiene las
amplitudes de las frecuencias en cada caso y el estado correspondiente del
rodamiento.

Datos = [Xdatos y];
Datos_Tabla= table(Xdatos,y);

end
```

A2.2. SCRIPT_TRATAMIENTO_DATOS_TRESESTADOS.

% TRATAMIENTO DE DATOS PARA EL DIAGNÓSTICO DEL ESTADO DE LOS RODAMIENTOS DE UN MOTOR DE INDUCCIÓN.

% SE DIVIDEN LOS FALLOS EN SANOS, FALLO LEVE Y MODERADO Y CON FALLO GRAVE Y TOTALMETE DESTRUIDO.

clear all; clc

tic %Inicializa el tiempo transcurrido

%La clasificación multiclase de los datos será:

% y = 0 ==> Rodamiento sano

% y = 1 ==> Fallos leves y moderados

% y = 2 ==> Fallos graves y muy graves.

% Vector de resultados, recogiendo los estados del rodamiento.

% Se consideran tres estados.

y = zeros(70,1);

y(1:20) = 0; % Los primeros 20 ensayos con estado sano.

y(21:50) = 1; % Los 30 siguientes con estados leve y moderado.

y(51:70) = 2; % Los restantes 20 con fallos graves y muy graves.

% Se define el nombre de las matrices que tendremos que cargar en cada caso

% Alimentacion = {'Datos_RED_NC2';'Datos_RED_NC1';'Datos_WEG_NC2';

% 'Datos_WEG_NC1'; 'Datos_AB1_NC2';'Datos_AB1_NC1';'Datos_AB2_NC2';

%

'Datos_AB2_NC1';'Datos_AB3_NC2';'Datos_AB3_NC1';'Datos_AB4_NC2';'Datos_AB4_NC1');

Alimentacion = {'Datos_AB4_NC1'};

niveles = {'_E0';'_E1';'_E2';'_E3';'_E4'}; % Estados reales del rodamiento.

fallos = {'BPFI';'BPFO';'BFTF';'BSF'}; % Las frecuencias características de fallo.

% Se crea un bucle para recorrer las variables de inicio a fin.

for l=1:length(Alimentacion)

 name = Alimentacion{l};

 load(name);

 name_xlx = strcat(name,'_Scores','.xlsx');

 Xdatos = zeros(0,0);

 % Se crea otro bucle para ir recorriendo las diferentes frecuencias

 % características.

 for g=1: length (fallos)

 % Se cargan todos los datos en una matriz de datos.

 Xtemp = zeros(0,0);

 % Se crea otro bucle para recorrer los diferentes estados.

 for a=1:length(niveles)

```
data= eval(['fallos{g},niveles{a}]);
data = data(3:end,:);
Xtemp = [Xtemp;data];
clear data
end
% Con estos tres bucles se consigue ir cargando los datos de cada
variable en función del tipo de alimentación, la carga, la frecuencia de fallo y
el estado del rodamiento.

% Se va introduciendo en Xdatos los datos de cada variable.
Xdatos = [Xdatos Xtemp];
clear Xtemp;

end
% Se interpola para identificar frecuencias donde la toma de datos del
motor de inducción ha sido defectuosamente tomada:
Xdatos = interpolar(Xdatos);

% Se preparan los datos eliminando las columnas con valores NaN (valores
vacíos).
[m, n] = size(Xdatos);
k = ~isnan(Xdatos());
sum_noNaN = sum(k,1);
indNaN = find(sum_noNaN<m);
Xdatos(:, indNaN) = [];
clear k sum_noNaN indNaN;

% Finalmente, se crean la variable en forma de tabla que contiene las
amplitudes de las frecuencias en cada caso y el estado correspondiente del
rodamiento.
Datos = [Xdatos y];
Datos_Tabla= table(Xdatos,y);

end
```

A2.3. SCRIPT_TRATAMIENTO_DATOS_SANO_FALLOS.

% TRATAMIENTO DE DATOS PARA EL DIAGNÓSTICO DEL ESTADO DE LOS
RODAMIENTOS DE UN MOTOR DE INDUCCIÓN.

% SE DIVIDEN LOS FALLOS EN SANOS Y CON FALLOS.

```
clear all; clc
```

```
tic %Inicializa el tiempo transcurrido
```

```
%La clasificación multiclase de los datos será:
```

```
% y = 0 =====> Rodamiento sano
```

```
% y = 1 =====> Fallos
```

```

% Vector de resultados, recogiendo los estados del rodamiento.
% Se consideran dos estados.
y = zeros(70,1);
y(1:20) = 0; % Los primeros 20 ensayos con estado sano.
y(21:70) = 1; % Los restantes 50, con fallos.

% Se define el nombre de las matrices que tendremos que cargar en cada
caso
% Alimentacion = {'Datos_RED_NC2';'Datos_RED_NC1';'Datos_WEG_NC2';
% 'Datos_WEG_NC1'; 'Datos_AB1_NC2';'Datos_AB1_NC1';'Datos_AB2_NC2';
%
'Datos_AB2_NC1';'Datos_AB3_NC2';'Datos_AB3_NC1';'Datos_AB4_NC2';'Dato
s_AB4_NC1'};

Alimentacion = {'Datos_AB4_NC2'};
niveles = {'_E0';'_E1';'_E2';'_E3';'_E4'}; % Estados reales del rodamiento.
fallos = {'BPFI';'BPFO';'BFTF';'BSF'}; % Las frecuencias características de fallo.

% Se crea un bucle para recorrer las variables de inicio a fin.
for l=1:length(Alimentacion)

    name = Alimentacion{l};
    load(name);
    name_xlx = strcat(name,'_Scores','.xlsx');
    Xdatos = zeros(0,0);
    % Se crea otro bucle para ir recorriendo las diferentes frecuencias
    % características.
    for g=1: length (fallos)
        % Se cargan todos los datos en una matriz de datos.
        Xtemp = zeros(0,0);
        % Se crea otro bucle para recorrer los diferentes estados.
        for a=1:length(niveles)
            data= eval([fallos{g},niveles{a}]);
            data = data(3:end,:);
            Xtemp = [Xtemp;data];
            clear data
        end
        % Con estos tres bucles se consigue ir cargando los datos de cada
        variable en función del tipo de alimentación, la carga, la frecuencia de fallo y
        el estado del rodamiento.

        % Se va introduciendo en Xdatos los datos de cada variable.
        Xdatos = [Xdatos Xtemp];
        clear Xtemp;

    end
    % Se interpola para identificar frecuencias donde la toma de datos del
    motor de inducción ha sido defectuosamente tomada:

```

```
Xdatos = interpolar(Xdatos);

% Se preparan los datos eliminando las columnas con valores NaN (valores vacíos).
[m, n] = size(Xdatos);
k = ~isnan(Xdatos());
sum_noNaN = sum(k,1);
indNaN = find(sum_noNaN<m);
Xdatos(:, indNaN) = [];
clear k sum_noNaN indNaN;

% Finalmente, se crean la variable en forma de tabla que contiene las amplitudes de las frecuencias en cada caso y el estado correspondiente del rodamiento.
Datos = [Xdatos y];
Datos_Tabla= table(Xdatos,y);

end
```

A2.4. SCRIPT_CONCORDANCIA.

% ANÁLISIS DEL ESTADO DE LOS RODAMIENTOS MEDIANTE ALGORITMOS NO SUPERVISADOS

```
% Se define la matriz de datos a evaluar (x) y el número de clusters a emplear (k), correspondiendo al número de estados del rodamiento.
x=Xdatos;
k=5;

%Se llama al algoritmo K-Means.
b=kmeans(x,k);

% Incremento en uno el Vector de resultados, representándose ahora los estados del 1-5, en lugar que del 0-4, para poder compararlo con la agrupación que hace K-Means

a=y+1;

%Se emplea la técnica de validación externa, basada en la comparativa entre pares de conjuntos de datos.
% Se definen las matrices que recogen el número de pares de ensayos que presentan igual grupo en la agrupación real (a) y en la realizada por el algoritmo (b)
%Serán matrices con una sola columna para así no comparar dos veces el mismo par de ensayos, creando para ello el siguiente bucle.
suma=0;
for contador=1:69
    suma=suma+contador;
end
```

```

concord_a = zeros(suma,1);
concord_b = zeros(suma,1);

%Se definen los siguientes parámetros:
% TP: Número de pares de ensayos que presentan igual estado en a y b.
% FP: Número de pares de ensayos que presentan igual estado en b, pero no
en a.
% FN: Número de pares de ensayos que presentan igual estado en a, pero no
en b.
% TN: Número de pares de ensayos que no tienen igual estado ni en a ni en b.
TP = 0;
FN = 0;
FP = 0;
TN = 0;

%Se crean dos bucles, uno para recorrer ambos vectores, a y b y otro para
obtener los parámetros descritos.
%Se excluirá la comparación entre un estado y el mismo, para no aumentar
%así el número de TP erróneamente.
%En el caso de que dos ensayos presenten igual estado en un vector, se
%añadirá, en su matriz correspondiente, el valor 1.
%Se obtienen los parámetros anteriores comparando las matrices generadas.
indice=1;
for cont1=1:70
    for cont2=cont1+1:70
        if(a(cont1) == a(cont2))
            concord_a(indice) = 1;
        end
        if(b(cont1) == b(cont2))
            concord_b(indice) = 1;
        end
        indice = indice+1; % Se introducen de este modo los valores 1 o 0 en las
matrices.
    end
end
for cont1=1:suma
    if(concord_a(cont1)== 1)
        if(concord_b(cont1)==1)
            TP = TP+1; %Se cuenta el número de pares de ensayos que se asignan
a igual grupo en ambos vectores, sin importar el estado.
        else
            FN=FN+1;
        end
    else
        if(concord_b(cont1)==1)
            FP = FP+1;
        else
            TN = TN+1;
        end
    end
end

```

```
end  
end
```

```
%Se obtiene la precisión con la que el algoritmo agrupa los ensayos, el  
%valor de Recall, el índice F1 y los parámetros asociados.
```

```
Precision = (TP / (TP+FP))*100
```

```
Recall = (TP / (TP+FN))*100
```

```
F1 =2*(Precision*Recall)/(Precision+Recall)
```

```
TP
```

```
FN
```

```
FP
```

```
TN
```

A2.5. SCRIPT_CONCORDANCIA_TRESESTADOS.

```
% ANÁLISIS DEL ESTADO DE LOS RODAMIENTOS MEDIANTE ALGORITMOS NO  
SUPERVISADOS.
```

```
% SE DIVIDEN LOS FALLOS EN SANOS, FALLO LEVE Y MODERADO Y CON  
FALLO GRAVE Y TOTALMETE DESTRUIDO.
```

```
% Se define la matriz de datos a evaluar (x) y el número de clusters a  
% emplear (k), en este caso 3.
```

```
x=Xdatos;
```

```
k=3;
```

```
% Se llama al algoritmo K-Means.
```

```
b=kmeans(x,k);
```

```
% Incremento en uno el Vector de resultados, representándose ahora los  
estados como 1, 2 y 3, en lugar de como 0, 1 y 2, para poder compararlo con  
la agrupación que hace K-Means
```

```
a=y+1;
```

```
%Se emplea la técnica de validación externa, basada en la comparativa entre  
pares de conjuntos de datos.
```

```
% Se definen las matrices que recogen el número de pares de ensayos que
```

```
% presentan igual grupo en la agrupación real (a) y en la realizada por el  
algoritmo (b)
```

```
%Serán matrices con una sola columna para así no comparar dos veces el
```

```
%mismo par de ensayos, creando para ello el siguiente bucle.
```

```
suma=0;
```

```
for contador=1:69
```

```
    suma=suma+contador;
```

```
end
```

```

concord_a = zeros(suma,1);
concord_b = zeros(suma,1);

%Se definen los siguientes parámetros:
% TP: Número de pares de ensayos que presentan igual estado en a y b.
% FP: Número de pares de ensayos que presentan igual estado en b, pero no
en a.
% FN: Número de pares de ensayos que presentan igual estado en a, pero no
en b.
% TN: Número de pares de ensayos que no tienen igual estado ni en a ni en b.
TP = 0;
FN = 0;
FP = 0;
TN = 0;

%Se crean dos bucles, uno para recorrer ambos vectores, a y b y otro para
obtener los parámetros descritos.
%Se excluirá la comparación entre un estado y el mismo, para no aumentar
%así el número de TP erróneamente.
%En el caso de que dos ensayos presenten igual estado en un vector, se
%añadirá, en su matriz correspondiente, el valor 1.
%Se obtienen los parámetros anteriores comparando las matrices generadas.
indice=1;
for cont1=1:70
    for cont2=cont1+1:70
        if(a(cont1) == a(cont2))
            concord_a(indice) = 1;
        end
        if(b(cont1) == b(cont2))
            concord_b(indice) = 1;
        end
        indice = indice+1; % Se introducen de este modo los valores 1 o 0 en las
matrices.
    end
end
for cont1=1:suma
    if(concord_a(cont1)== 1)
        if(concord_b(cont1)==1)
            TP = TP+1; %Se cuenta el número de pares de ensayos que se asignan
a igual grupo en ambos vectores, sin importar el estado.
        else
            FN=FN+1;
        end
    else
        if(concord_b(cont1)==1)
            FP = FP+1;
        else
            TN = TN+1;
        end
    end
end

```

```

    end
end

```

```

%Se obtiene la precisión con la que el algoritmo agrupa los ensayos, el
%valor de Recall, el índice F1 y los parámetros asociados.

```

```

Precision = (TP / (TP+FP))*100

```

```

Recall = (TP / (TP+FN))*100

```

```

F1 =2*(Precision*Recall)/(Precision+Recall)

```

```

TP

```

```

FN

```

```

FP

```

```

TN

```

A2.6. SCRIPT_CONCORDANCIA_SANO_FALLOS.

```

% ANÁLISIS DEL ESTADO DE LOS RODAMIENTOS MEDIANTE ALGORITMOS NO
SUPERVISADOS

```

```

% SE DIVIDEN LOS ESTADOS EN SANOS Y CON FALLOS.

```

```

% Se define la matriz de datos a evaluar (x) y el número de clusters a
% emplear (k), en este caso 2.

```

```

x=Xdatos;

```

```

k=2;

```

```

% Se llama al algoritmo K-Means.

```

```

b=kmeans(x,k);

```

```

% Incremento en uno el Vector de resultados, representándose ahora los
estados como 1 y 2, en lugar de como 0 y 1, para poder compararlo con la
agrupación que hace K-Means

```

```

a=y+1;

```

```

%Se emplea la técnica de validación externa, basada en la comparativa entre
pares de conjuntos de datos.

```

```

% Se definen las matrices que recogen el número de pares de ensayos que
% presentan igual grupo en la agrupación real (a) y en la realizada por el
algoritmo (b)

```

```

%Serán matrices con una sola columna para así no comparar dos veces el
% mismo par de ensayos, creando para ello el siguiente bucle.

```

```

suma=0;

```

```

for contador=1:69

```

```

    suma=suma+contador;

```

```

end

```

```

concord_a = zeros(suma,1);

```

```

concord_b = zeros(suma,1);

```

```

%Se definen los siguientes parámetros:
% TP: Número de pares de ensayos que presentan igual estado en a y b.
% FP: Número de pares de ensayos que presentan igual estado en b, pero no
en a.
% FN: Número de pares de ensayos que presentan igual estado en a, pero no
en b.
% TN: Número de pares de ensayos que no tienen igual estado ni en a ni en b.
TP = 0;
FN = 0;
FP = 0;
TN = 0;

%Se crean dos bucles, uno para recorrer ambos vectores, a y b y otro para
obtener los parámetros descritos.
%Se excluirá la comparación entre un estado y el mismo, para no aumentar
%así el número de TP erróneamente.
%En el caso de que dos ensayos presenten igual estado en un vector, se
%añadirá, en su matriz correspondiente, el valor 1.
%Se obtienen los parámetros anteriores comparando las matrices generadas.
indice=1;
for cont1=1:70
    for cont2=cont1+1:70
        if(a(cont1) == a(cont2))
            concord_a(indice) = 1;
        end
        if(b(cont1) == b(cont2))
            concord_b(indice) = 1;
        end
        indice = indice+1; % Se introducen de este modo los valores 1 o 0 en las
matrices.
    end
end
for cont1=1:suma
    if(concord_a(cont1)== 1)
        if(concord_b(cont1)==1)
            TP = TP+1; %Se cuenta el número de pares de ensayos que se asignan
a igual grupo en ambos vectores, sin importar el estado.
        else
            FN=FN+1;
        end
    else
        if(concord_b(cont1)==1)
            FP = FP+1;
        else
            TN = TN+1;
        end
    end
end
end

```

%Se obtiene la precisión con la que el algoritmo agrupa los ensayos, el
 %valor de Recall, el índice F1 y los parámetros asociados.

Precision = (TP / (TP+FP))*100

Recall = (TP / (TP+FN))*100

F1 =2*(Precision*Recall)/(Precision+Recall)

TP

FN

FP

TN

A2.7. SCRIPT_CONCORDANCIA_KMEDOIDS.

% ANÁLISIS DEL ESTADO DE LOS RODAMIENTOS MEDIANTE EL ALGORITMO
 NO

% SUPERVISADOS K-MEDOIDS

% Se define la matriz de datos a evaluar (x) y el número de clusters a
 % emplear (k), correspondiendo al número de estados del rodamiento.

x=Xdatos;

k=5;

%Se llama al algoritmo K-Medoids.

b=kmedoids(x,k);

% Incremento en uno el Vector de resultados, representándose ahora los
 estados del 1-5, en lugar que del 0-4, para poder compararlo con la
 agrupación que hace K-Means

a=y+1;

%Se emplea la técnica de validación externa, basada en la comparativa entre
 pares de conjuntos de datos.

% Se definen las matrices que recogen el número de pares de ensayos que

% presentan igual grupo en la agrupación real (a) y en la realizada por el
 algoritmo (b)

%Serán matrices con una sola columna para así no comparar dos veces el

%mismo par de ensayos, creando para ello el siguiente bucle.

suma=0;

for contador=1:69

 suma=suma+contador;

end

concord_a = zeros(suma,1);

concord_b = zeros(suma,1);

%Se definen los siguientes parámetros:

% TP: Número de pares de ensayos que presentan igual estado en a y b.

```

% FP: Número de pares de ensayos que presentan igual estado en b, pero no
en a.
% FN: Número de pares de ensayos que presentan igual estado en a, pero no
en b.
% TN: Número de pares de ensayos que no tienen igual estado ni en a ni en b.
TP = 0;
FN = 0;
FP = 0;
TN = 0;

%Se crean dos bucles, uno para recorrer ambos vectores, a y b y otro para
obtener los parámetros descritos.
%Se excluirá la comparación entre un estado y el mismo, para no aumentar
%así el número de TP erróneamente.
%En el caso de que dos ensayos presenten igual estado en un vector, se
%añadirá, en su matriz correspondiente, el valor 1.
%Se obtienen los parámetros anteriores comparando las matrices generadas.
indice=1;
for cont1=1:70
    for cont2=cont1+1:70
        if(a(cont1) == a(cont2))
            concord_a(indice) = 1;
        end
        if(b(cont1) == b(cont2))
            concord_b(indice) = 1;
        end
        indice = indice+1; % Se introducen de este modo los valores 1 o 0 en las
matrices.
    end
end
for cont1=1:suma
    if(concord_a(cont1)== 1)
        if(concord_b(cont1)==1)
            TP = TP+1; %Se cuenta el número de pares de ensayos que se asignan
a igual grupo en ambos vectores, sin importar el estado.
        else
            FN=FN+1;
        end
    else
        if(concord_b(cont1)==1)
            FP = FP+1;
        else
            TN = TN+1;
        end
    end
end
end

%Se obtiene la precisión con la que el algoritmo agrupa los ensayos, el
%valor de Recall y el índice F1.

```

Precision = (TP / (TP+FP))*100

Recall = (TP / (TP+FN))*100

F1 = 2*(Precision*Recall)/(Precision+Recall)

A2.8. SCRIPT_CONCORDANCIA_HIERARCHICAL_CLUSTERING.

% ANÁLISIS DEL ESTADO DE LOS RODAMIENTOS MEDIANTE EL ALGORITMO
NO

% SUPERVISADO HIERARCHICAL CLUSTERING

% Se define la matriz de datos a evaluar (x)

X=Xdatos;

% Se emplea la función pdist para obtener la distancia entre cada par de

% objetos formados por un conjunto de datos. Dicha información se recoge en
el vector Y.

Y = pdist(X);

% La función linkage agrupa los objetos más próximos entre sí creando un

% cluster binario. A continuación, repite el proceso con los clusters

% creados hasta que todos quedan emparejados, creando así un árbol

% jerárquico.

% La matriz Z muestra en sus dos primeras columnas los clusters agrupados
entre sí en cada caso y en la tercera la distancia entre ellos.

Z = linkage(Y);

% Se establece el dendograma del árbol jerárquico creado por la función

% anterior, mostrando gráficamente las agrupaciones.

dendrogram(Z)

% A continuación, se obtiene la matriz T, donde recogen el estado que se

% asigna a cada uno de los ensayos realizados al motor. Se establece el

% número de clusters en los que se quiere que se agrupen los datos, cinco en
este caso.

% Para entender la clasificación, al indicar 5 clusters, se traza una

% horizontal en el dendograma atravesando 5 verticales y se agrupa los datos
en consecuencia.

k=5;

T = cluster(Z,'maxclust',k);

% Se incrementa en uno el Vector de resultados obtenido con el

Script_Tratamiento_Datos, representándose ahora los estados del 1-5, en

lugar que del 0-4, para poder compararlo con la agrupación que hace
Hierarchical clustering

a=y+1;

```

%Se emplea la técnica de validación externa, basada en la comparativa entre
pares de conjuntos de datos.
% Se definen las matrices que recogen el número de pares de ensayos que
% presentan igual grupo en la agrupación real (a) y en la realizada por el
algoritmo (b)
%Serán matrices con una sola columna para así no comparar dos veces el
%mismo par de ensayos, creando para ello el siguiente bucle.
suma=0;
for contador=1:69
    suma=suma+contador;
end
concord_a = zeros(suma,1);
concord_T = zeros(suma,1);

%Se definen los siguientes parámetros:
% TP: Número de pares de ensayos que presentan igual estado en a y b.
% FP: Número de pares de ensayos que presentan igual estado en b pero no
en a.
% FN: Número de pares de ensayos que presentan igual estado en a pero no
en b.
% TN: Número de pares de ensayos que no tienen igual estado ni en a ni en b.
TP = 0;
FN = 0;
FP = 0;
TN = 0;

%Se crean dos bucles, uno para recorrer ambos vectores, a y b y otro para
%obtener los parámetros descritos.
%Se excluirá la comparación entre un estado y el mismo, para no aumentar
%así el número de TP erróneamente.
%En el caso de que dos ensayos presenten igual estado en un vector, se
%añadirá, en su matriz correspondiente, el valor 1.
%Se obtienen los parámetros anteriores comparando las matrices generadas.
indice=1;
for cont1=1:70
    for cont2=cont1+1:70
        if(a(cont1) == a(cont2))
            concord_a(indice) = 1;
        end
        if(T(cont1) == T(cont2))
            concord_T(indice) = 1;
        end
        indice = indice+1; % Se introducen de este modo los valores 1 o 0 en las
matrices.
    end
end
for cont1=1:suma
    if(concord_a(cont1)== 1)

```

```

    if(concord_T(cont1)==1)
        TP = TP+1; %Cuento el número de pares de ensayos que se asignan a
igual grupo en ambos vectores, sin importar el estado.
    else
        FN=FN+1;
    end
else
    if(concord_T(cont1)==1)
        FP = FP+1;
    else
        TN = TN+1;
    end
end
end
end
end

```

```

%Se obtiene la precisión con la que el algoritmo agrupa los ensayos, el
%parámetro Recall y el índice F1
Precision = (TP / (TP+FP))*100
Recall = (TP / (TP+FN))*100
F1 = 2*(Precision*Recall)/(Precision+Recall)

```

A2.9. SCRIPT_TRATAMIENTO_DATOS_NC2yNC1.

```

% TRATAMIENTO DE DATOS PARA EL DIAGNÓSTICO DEL ESTADO DE LOS
RODAMIENTOS DE UN MOTOR DE INDUCCIÓN.

```

```

% NO SE HACE DISTINCIÓN DEL NIVEL DE CARGA

```

```

clear all; clc
tic %Inicializa el tiempo transcurrido

%La clasificación multiclase de los datos será:
% y = 0 ====> Rodamiento sano
% y = 1 ====> Fallo leve
% y = 2 ====> Fallo moderado
% y = 3 ====> Fallo Grave
% y = 4 ====> Fallo muy grave

% Vector de resultados, recogiendo los estados del rodamiento.
y = zeros(70,1);
y(1:20) = 0;
y(21:35) = 1;
y(36:50) = 2;
y(51:60) = 3;
y(61:70) = 4;

```

```

% Se define el nombre de las matrices que tendremos que cargar en cada
caso
% Alimentacion = {'Datos_RED_NC2';'Datos_RED_NC1';'Datos_WEG_NC2';
% 'Datos_WEG_NC1'; 'Datos_AB1_NC2';'Datos_AB1_NC1';'Datos_AB2_NC2';
%
'Datos_AB2_NC1';'Datos_AB3_NC2';'Datos_AB3_NC1';'Datos_AB4_NC2';'Dato
s_AB4_NC1'};

Alimentacion = {'Datos_AB4_NC2'};
niveles = {'_E0';'_E1';'_E2';'_E3';'_E4'}; % Estados reales del rodamiento.
fallos = {'BPFI';'BPFO';'BFTF';'BSF'}; %Las frecuencias características de fallo.

% Se crea un bucle para recorrer las variables de inicio a fin.
for l=1:length(Alimentacion)

    name = Alimentacion{l};
    load(name);
    name_xlx = strcat(name,'_Scores','.xlsx');
    Xdatos = zeros(0,0);
    % Se crea otro bucle para ir recorriendo las diferentes frecuencias
    % características.
    for g=1: length (fallos)
        % Se cargan todos los datos en una matriz de datos.
        Xtemp = zeros(0,0);
        % Se crea otro bucle para recorrer los diferentes estados.
        for a=1:length(niveles)
            data= eval(['fallos{g},niveles{a}']);
            data = data(3:end,:);
            Xtemp = [Xtemp;data];
            clear data
        end
        % Con estos tres bucles se consigue ir cargando los datos de cada
        variable en función del tipo de alimentación, la carga, la frecuencia de fallo y
        el estado del rodamiento.

        % Se va introduciendo en Xdatos los datos de cada variable.
        Xdatos = [Xdatos Xtemp];
        clear Xtemp;

    end
    % Se interpola para identificar frecuencias donde la toma de datos del
    motor de inducción ha sido defectuosamente tomados:
    Xdatos = interpolar(Xdatos);
end
% Se preparan los datos eliminando las columnas con valores NaN (valores
vacíos).
[m, n] = size(Xdatos);
k = ~isnan(Xdatos());
sum_noNaN = sum(k,1);

```

```
indNaN = find(sum_noNaN<m);
Xdatos(:, indNaN) = [];
clear k sum_noNaN indNaN;
```

% Se repite el proceso con el nivel de carga bajo.

```
Alimentacion1 = {'Datos_AB4_NC1'};
niveles = {'_E0'; '_E1'; '_E2'; '_E3'; '_E4'}; % Estados reales del rodamiento.
fallos1 = {'BPF1'; 'BPF0'; 'BTF1'; 'BSF'}; % Las frecuencias características de fallo.
```

% Se crea un bucle para recorrer las variables de inicio a fin.

```
for l=1:length(Alimentacion1)
```

```
    name1 = Alimentacion1{l};
    load(name1);
    name_xlx1 = strcat(name1, '_Scores', '.xlsx');
    Xdatos1 = zeros(0,0);
    % Se crea otro bucle para ir recorriendo las diferentes frecuencias
    % características.
```

```
    for g=1:length(fallos1)
```

```
        % Se cargan todos los datos en una matriz de datos.
```

```
        Xtemp1 = zeros(0,0);
```

```
        % Se crea otro bucle para recorrer los diferentes estados.
```

```
        for a=1:length(niveles)
```

```
            data1 = eval([fallos1{g},niveles{a}]);
```

```
            data1 = data1(3:end,:);
```

```
            Xtemp1 = [Xtemp1;data1];
```

```
            clear data
```

```
        end
```

% Con estos tres bucles se consigue ir cargando los datos de cada variable en función del tipo de alimentación, la carga, la frecuencia de fallo y el estado del rodamiento.

```
    % Se va introduciendo en Xdatos los datos de cada variable.
```

```
    Xdatos1 = [Xdatos1 Xtemp1];
```

```
    clear Xtemp1;
```

```
end
```

% Se interpola para identificar frecuencias donde la toma de datos del motor de inducción ha sido defectuosamente tomados:

```
Xdatos1 = interpolar(Xdatos1);
```

% Se preparan los datos eliminando las columnas con valores NaN (valores vacíos).

```
[m, n] = size(Xdatos1);
```

```
k = ~isnan(Xdatos1());
```

```
sum_noNaN = sum(k,1);
```

```
indNaN = find(sum_noNaN<m);
```

```
Xdatos1(:, indNaN) = [];
```

```

clear k sum_noNaN indNaN;

% Se unen en la misma variable ambos conjuntos de datos.
Xdatos2=[Xdatos Xdatos1];

% Finalmente, se crean la variable en forma de tabla que contiene las
% amplitudes de las frecuencias en cada caso y el estado correspondiente
% del rodamiento.
Datos = [Xdatos2 y];
Datos_Tabla= table(Xdatos2,y);

end

```

A2.10. SCRIPT_TRATAMIENTO_DATOS_50HzNC2.

```

% TRATAMIENTO DE DATOS PARA EL DIAGNÓSTICO DEL ESTADO DE LOS
% RODAMIENTOS DE UN MOTOR DE INDUCCIÓN.

% FRECUENCIA DE ALIMENTACIÓN 50HZ Y NIVEL DE CARGA NOMINAL

clear all; clc
tic %Inicializa el tiempo transcurrido

%La clasificación multiclase de los datos será:
% y = 0 ====> Rodamiento sano
% y = 1 ====> Fallo leve
% y = 2 ====> Fallo moderado
% y = 3 ====> Fallo Grave
% y = 4 ====> Fallo muy grave

% Vector de resultados, recogiendo los estados del rodamiento.
y = zeros(70,1);
y(1:20) = 0;
y(21:35) = 1;
y(36:50) = 2;
y(51:60) = 3;
y(61:70) = 4;

% Se define el nombre de las matrices que tendremos que cargar en cada
% caso
% Alimentacion = {'Datos_RED_NC2';'Datos_RED_NC1';'Datos_WEG_NC2';
% 'Datos_WEG_NC1'; 'Datos_AB1_NC2';'Datos_AB1_NC1';'Datos_AB2_NC2';
%
% 'Datos_AB2_NC1';'Datos_AB3_NC2';'Datos_AB3_NC1';'Datos_AB4_NC2';'Dato
% s_AB4_NC1'};

Alimentacion = {'Datos_RED_NC2'};

```

```
niveles = {'_E0';'_E1';'_E2';'_E3';'_E4'}; % Estados reales del rodamiento.
fallos = {'BPMI';'BPFO';'BFTF';'BSF'}; %Las frecuencias características de fallo.

% Se crea un bucle para recorrer las variables de inicio a fin.
for l=1:length(Alimentacion)

    name = Alimentacion{l};
    load(name);
    name_xlx = strcat(name,'_Scores','.xlsx');
    Xdatos = zeros(0,0);
    % Se crea otro bucle para ir recorriendo las diferentes frecuencias
    % características.
    for g=1:length(fallos)
        % Se cargan todos los datos en una matriz de datos.
        Xtemp = zeros(0,0);
        % Se crea otro bucle para recorrer los diferentes estados.
        for a=1:length(niveles)
            data= eval([fallos{g},niveles{a}]);
            data = data(3:end,:);
            Xtemp = [Xtemp;data];
            clear data
        end
        % Con estos tres bucles se consigue ir cargando los datos de cada
        variable en función del tipo de alimentación, la carga, la frecuencia de fallo y
        el estado del rodamiento.

        % Se va introduciendo en Xdatos los datos de cada variable.
        Xdatos = [Xdatos Xtemp];
        clear Xtemp;

    end
    % Se interpola para identificar frecuencias donde la toma de datos del
    motor de inducción ha sido defectuosamente tomados:
    Xdatos = interpolar(Xdatos);
end
% Se preparan los datos eliminando las columnas con valores NaN (valores
vacíos).
[m, n] = size(Xdatos);
k = ~isnan(Xdatos());
sum_noNaN = sum(k,1);
indNaN = find(sum_noNaN<m);
Xdatos(:, indNaN) = [];
clear k sum_noNaN indNaN;

% Se repite el proceso con la alimentación WEG

Alimentacion1 = {'Datos_WEG_NC2'};
niveles = {'_E0';'_E1';'_E2';'_E3';'_E4'}; % Estados reales del rodamiento.
fallos1 = {'BPMI';'BPFO';'BFTF';'BSF'}; %Las frecuencias características de fallo.
```

```

% Se crea un bucle para recorrer las variables de inicio a fin.
for l=1:length(Alimentacion1)

    name1 = Alimentacion1{l};
    load(name1);
    name_xlx1 = strcat(name1, '_Scores', '.xlsx');
    Xdatos1 = zeros(0,0);
    % Se crea otro bucle para ir recorriendo las diferentes frecuencias
    % características.
    for g=1: length (fallos1)
        % Se cargan todos los datos en una matriz de datos.
        Xtemp1 = zeros(0,0);
        % Se crea otro bucle para recorrer los diferentes estados.
        for a=1:length(niveles)
            data1= eval([fallos1{g},niveles{a}]);
            data1 = data1(3:end,:);
            Xtemp1 = [Xtemp1;data1];
            clear data
        end
        % Con estos tres bucles se consigue ir cargando los datos de cada
        variable en función del tipo de alimentación, la carga, la frecuencia de fallo y
        el estado del rodamiento.

        % Se va introduciendo en Xdatos los datos de cada variable.
        Xdatos1 = [Xdatos1 Xtemp1];
        clear Xtemp1;

    end
    % Se interpola para identificar frecuencias donde la toma de datos del
    motor de inducción ha sido defectuosamente tomados:
    Xdatos1 = interpolar(Xdatos1);
end
% Se preparan los datos eliminando las columnas con valores NaN (valores
vacíos).
[m, n] = size(Xdatos1);
k = ~isnan(Xdatos1());
sum_noNaN = sum(k,1);
indNaN = find(sum_noNaN<m);
Xdatos1(:, indNaN) = [];
clear k sum_noNaN indNaN;

% Se repite el proceso con la alimentación AB1

Alimentacion2 = {'Datos_AB1_NC2'};
niveles = {'_E0';'_E1';'_E2';'_E3';'_E4'}; % Estados reales del rodamiento.
fallos2 = {'BPFI';'BPFO';'BFTF';'BSF'}; %Las frecuencias características de fallo.

% Se crea un bucle para recorrer las variables de inicio a fin.

```

```
for l=1:length(Alimentacion2)

    name2 = Alimentacion2{l};
    load(name2);
    name_xlx2 = strcat(name2, '_Scores', '.xlsx');
    Xdatos2 = zeros(0,0);
    % Se crea otro bucle para ir recorriendo las diferentes frecuencias
    % características.
    for g=1: length (fallos2)
        % Se cargan todos los datos en una matriz de datos.
        Xtemp2 = zeros(0,0);
        % Se crea otro bucle para recorrer los diferentes estados.
        for a=1:length(niveles)
            data2= eval([fallos2{g},niveles{a}]);
            data2 = data2(3:end,:);
            Xtemp2 = [Xtemp2;data2];
            clear data
        end
        % Con estos tres bucles se consigue ir cargando los datos de cada
        variable en función del tipo de alimentación, la carga, la frecuencia de fallo y
        el estado del rodamiento.

        % Se va introduciendo en Xdatos los datos de cada variable.
        Xdatos2 = [Xdatos2 Xtemp2];
        clear Xtemp2;

    end
    % Se interpola para identificar frecuencias donde la toma de datos del
    motor
    % de inducción ha sido defectuosamente tomados:
    Xdatos2 = interpolar(Xdatos2);

    % Se preparan los datos eliminando las columnas con valores NaN (valores
    vacíos).
    [m, n] = size(Xdatos2);
    k = ~isnan(Xdatos2());
    sum_noNaN = sum(k,1);
    indNaN = find(sum_noNaN<m);
    Xdatos2(:, indNaN) = [];
    clear k sum_noNaN indNaN;

    % Se unen en la misma variable los tres conjuntos de datos.
    Xdatos3=[Xdatos Xdatos1 Xdatos2];

    % Finalmente, se crean la variable en forma de tabla que contiene las
    % amplitudes de las frecuencias en cada caso y el estado correspondiente
    % del rodamiento.
    Datos = [Xdatos3 y];
```

```
Datos_Tabla= table(Xdatos3,y);
```

```
end
```

A2.11. SCRIPT_CONCORDANCIA_NC2yNC1.

```
% ANÁLISIS DEL ESTADO DE LOS RODAMIENTOS MEDIANTE ALGORITMOS NO SUPERVISADOS
```

```
% NO SE HACE DISTINCIÓN DEL NIVEL DE CARGA
```

```
% ALGORITMO K-MEANS
```

```
% Se define la matriz de datos a evaluar (x) y el número de clusters a emplear (k), correspondiendo al número de estados del rodamiento.
```

```
x=Xdatos2;
```

```
k=5;
```

```
%Se llama al algoritmo K-Means.
```

```
b=kmeans(x,k);
```

```
% Incremento en uno el Vector de resultados, representándose ahora los estados del 1-5, en lugar que del 0-4, para poder compararlo con la agrupación que hace K-Means
```

```
a=y+1;
```

```
%Se emplea la técnica de validación externa, basada en la comparativa entre pares de conjuntos de datos.
```

```
% Se definen las matrices que recogen el número de pares de ensayos que
```

```
% presentan igual grupo en la agrupación real (a) y en la realizada por el algoritmo (b)
```

```
%Serán matrices con una sola columna para así no comparar dos veces el
```

```
%mismo par de ensayos, creando para ello el siguiente bucle.
```

```
suma=0;
```

```
for contador=1:69
```

```
    suma=suma+contador;
```

```
end
```

```
concord_a = zeros(suma,1);
```

```
concord_b = zeros(suma,1);
```

```
%Se definen los siguientes parámetros:
```

```
% TP: Número de pares de ensayos que presentan igual estado en a y b.
```

```
% FP: Número de pares de ensayos que presentan igual estado en b pero no en a.
```

```
% FN: Número de pares de ensayos que presentan igual estado en a pero no en b.
```

```
% TN: Número de pares de ensayos que no tienen igual estado ni en a ni en b.
```

```
TP = 0;
```

```
FN = 0;  
FP = 0;  
TN = 0;
```

```
%Se crean dos bucles, uno para recorrer ambos vectores, a y b y otro para  
obtener los parámetros descritos.  
%Se excluirá la comparación entre un estado y el mismo, para no aumentar  
%así el número de TP erróneamente.  
%En el caso de que dos ensayos presenten igual estado en un vector, se  
%añadirá, en su matriz correspondiente, el valor 1.  
%Se obtienen los parámetros anteriores comparando las matrices generadas.
```

```
indice=1;  
for cont1=1:70  
    for cont2=cont1+1:70  
        if(a(cont1) == a(cont2))  
            concord_a(indice) = 1;  
        end  
        if(b(cont1) == b(cont2))  
            concord_b(indice) = 1;  
        end  
        indice = indice+1; % Se introducen de este modo los valores 1 o 0 en las  
matrices.
```

```
    end  
end  
for cont1=1:suma  
    if(concord_a(cont1)== 1)  
        if(concord_b(cont1)==1)  
            TP = TP+1; %Cuento el número de pares de ensayos que se asignan a  
igual grupo en ambos vectores, sin importar el estado.
```

```
        else  
            FN=FN+1;  
        end  
    else  
        if(concord_b(cont1)==1)  
            FP = FP+1;  
        else  
            TN = TN+1;  
        end  
    end  
end  
end
```

```
%Se obtiene la precisión con la que el algoritmo agrupa los ensayos, el  
%parámetro Recall y el índice F1
```

```
Precision = (TP / (TP+FP))*100  
Recall = (TP / (TP+FN))*100  
F1 =2*(Precision*Recall)/(Precision+Recall)
```

```
%ALGORITMO HIERARCHICAL CLUSTERING

% Se define la matriz de datos a evaluar (x)
X=Xdatos2;

% Se emplea la función pdist para obtener la distancia entre cada par de
% objetos formados por un conjunto de datos. Dicha información se recoge en
% el vector Y.
Y = pdist(X);

% La función linkage agrupa los objetos más próximos entre sí creando un
% cluster binario. A continuación, repite el proceso con los clusters
% creados hasta que todos quedan emparejados, creando así un árbol
% jerárquico.
% La matriz Z muestra en sus dos primeras columnas los clusters agrupados
% entre sí en cada caso y en la tercera la distancia entre ellos.
Z = linkage(Y);

% A continuación, se obtiene la matriz T, donde recogen el estado que se
% asigna a cada uno de los ensayos realizados al motor. Se establece el
% número de clusters en los que se quiere que se agrupen los datos, cinco en
% este caso.

% Para entender la clasificación, al indicar 5 clusters, se traza una
% horizontal en el dendograma atravesando 5 verticales y se agrupa los datos
% en consecuencia.

k=5;
T = cluster(Z,'maxclust',k);

% Se incrementa en uno el Vector de resultados obtenido con el
% Scipt_Tratamiento_Datos, representándose ahora los estados
% del 1-5, en lugar que del 0-4, para poder compararlo con la agrupación que
% hace Hierarchical clustering
a=y+1;

%Se emplea la técnica de validación externa, basada en la comparativa entre
% pares de conjuntos de datos.
% Se definen las matrices que recogen el número de pares de ensayos que
% presentan igual grupo en la agrupación real (a) y en la realizada por el
% algoritmo (b)
%Serán matrices con una sola columna para así no comparar dos veces el
% mismo par de ensayos, creando para ello el siguiente bucle.
suma=0;
for contador=1:69
    suma=suma+contador;
end
```

```
concord_a = zeros(suma,1);
concord_T = zeros(suma,1);

%Se definen los siguientes parámetros:
% TP: Número de pares de ensayos que presentan igual estado en a y b.
% FP: Número de pares de ensayos que presentan igual estado en b pero no
en a.
% FN: Número de pares de ensayos que presentan igual estado en a pero no
en b.
% TN: Número de pares de ensayos que no tienen igual estado ni en a ni en b.
TP = 0;
FN = 0;
FP = 0;
TN = 0;

%Se crean dos bucles, uno para recorrer ambos vectores, a y b y otro para
obtener los parámetros descritos.
%Se excluirá la comparación entre un estado y el mismo, para no aumentar
%así el número de TP erróneamente.
%En el caso de que dos ensayos presenten igual estado en un vector, se
%añadirá, en su matriz correspondiente, el valor 1.
%Se obtienen los parámetros anteriores comparando las matrices generadas.
indice=1;
for cont1=1:70
    for cont2=cont1+1:70
        if(a(cont1) == a(cont2))
            concord_a(indice) = 1;
        end
        if(T(cont1) == T(cont2))
            concord_T(indice) = 1;
        end
        indice = indice+1; % Se introducen de este modo los valores 1 o 0 en las
matrices.
    end
end
for cont1=1:suma
    if(concord_a(cont1)== 1)
        if(concord_T(cont1)==1)
            TP = TP+1; %Cuento el número de pares de ensayos que se asignan a
igual grupo en ambos vectores, sin importar el estado.
        else
            FN=FN+1;
        end
    else
        if(concord_T(cont1)==1)
            FP = FP+1;
        else
            TN = TN+1;
        end
    end
end
```

```
end  
end
```

```
%Se obtiene la precisión con la que el algoritmo agrupa los ensayos, el  
%parámetro Recall y el índice F1  
Precision = (TP / (TP+FP))*100  
Recall = (TP / (TP+FN))*100  
F1 =2*(Precision*Recall)/(Precision+Recall)
```

