



UNIVERSIDAD DE GUANAJUATO

División de Ingenierías
Campus Irapuato - Salamanca



UNIVERSIDAD DE VALLADOLID

Escuela de Ingenierías
Industriales

*“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

En el formato de doble titulación para obtener el grado de:

DOCTOR

EN INGENIERÍA ELÉCTRICA
por la Universidad de Guanajuato

EN INGENIERÍA INDUSTRIAL
por la Universidad de Valladolid

Presenta:

Ignacio Martín Díaz

Directores:

*Dr. Daniel Morínigo Sotelo, Dr. Óscar Duque Pérez
Dr. René de Jesús Romero Troncoso*

Dedicatoria

A mis padres, y a Sara porque son ellos los que me han enseñado el valor del trabajo, del servicio y del amor. También expreso mi gratitud a mis directores de tesis por sus extraordinarios consejos para llevarla a cabo. A Daniel Moríñigo y a Óscar Duque, por parte de la Universidad de Valladolid, porque en todo momento confiaron en mí y me introdujeron en este mundo donde confluyen el aprendizaje estadístico y las máquinas eléctricas. A mi director de tesis, René de J. Romero Troncoso, por parte de la Universidad de Guanajuato, porque me dió invaluable consejos para lograr la publicación de los productos científicos a los que dió lugar esta tesis. Por supuesto, no me olvido de los maestros y compañeros con los que compartí tanto tiempo en la Universidad de Valladolid, así como mis compañeros más recientes en la Universidad de Guanajuato que me hicieron sentir como en casa a pesar de la distancia.

Y, por supuesto, a los profesores del departamento de Estadística de la Universidad de Valladolid por sus valiosas asesorías al inicio de este periodo de formación.

Agradecimientos institucionales

A la Universidad de Guanajuato por permitirme realizar mis estudios de Doctorado y a la División de Ingenierías Campus Irapuato-Salamanca. Les agradezco el haberme proporcionado el equipo y las instalaciones necesarias para terminar mis estudios y por hacerme sentir parte de esta gran institución como lo es la Universidad de Guanajuato.



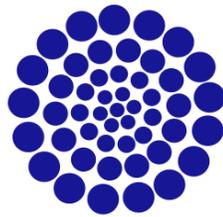
Al profesorado de la Escuela de Ingenierías Industriales por haberme proporcionado una formación excelente durante todos los años de mi carrera. Al departamento de Ingeniería Eléctrica de la Escuela de Ingenierías Industriales (Universidad de Valladolid) por haberme proporcionado el capital humano, así como el equipo y las instalaciones necesarias para realizar mis estudios de doctorado y por hacerme sentir parte de esta gran institución durante todos los años de mi carrera académica. Finalmente, me gustaría agradecer a la Universidad de Valladolid por las ayudas de movilidad otorgadas tan necesarias para realizar las Estancias Breves que han permitido el desarrollo de esta Tesis Doctoral.



Universidad de Valladolid

Al Consejo Nacional de Ciencia y Tecnología por la beca otorgada mediante el apoyo No. 741702/598078

- *Título de trabajo:* 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
- *Autor:* Ignacio Martín Díaz
- *Asesor:* Dr. René de Jesús Romero Troncoso



CONACYT

Consejo Nacional de Ciencia y Tecnología

Resumen

Los sistemas en los que intervienen motores de inducción (MI) consumen la mayor parte de energía eléctrica del sector industrial. Los fallos mecánicos que en principio no son catastróficos tales como los producidos en alguna de las barras de la jaula del rotor de un MI, pueden desarrollarse a lo largo del tiempo pudiendo causar el mal funcionamiento de algún otro componente de la máquina como por ejemplo el estátor, dando lugar a riesgos relacionados con la seguridad de las personas así como a elevados costes a causa de la parada de la producción. Por lo tanto, para reducir estos inconvenientes y asegurar la disponibilidad, fiabilidad y buen rendimiento de las máquinas es necesario desarrollar métodos de diagnóstico que puedan ser implementados en la práctica para llevar a cabo una detección incipiente de fallos en las barras del rotor. El análisis de la corriente estatórica se ha establecido como una de las magnitudes principales para llevar a cabo un diagnóstico no invasivo de fallos en el rotor. Sin embargo, la amplia variedad de motores industriales alimentados por inversor junto con la cantidad limitada y desequilibrada de datos con los que normalmente se dispone para construir una herramienta de diagnóstico, donde la clase de motor sano predomina sobre el resto de condiciones de fallo a las que pueda estar sometida la máquina, complica el diagnóstico inteligente de fallos bajo estas condiciones.

Para resolver esta problemática esta tesis desarrolla varias metodologías de diagnóstico. La primera de ellas está orientada a reducir la incertidumbre en la localización de las frecuencias de fallo de barra a través de la transformada *Multiple Signal Classification* (MUSIC) para a continuación, cuantificar la severidad del fallo por medio de la *Fast Fourier Transform* (FFT). Esto permite que combinando MUSIC con la FFT se pueda cuantificar la severidad de fallos intermedios a la barra rota en motores alimentados por inversor. La segunda metodología es una propuesta original que aborda el diagnóstico automático de fallos cuando el conjunto de datos de partida es pequeño y desequilibrado. La metodología consiste en las siguientes etapas: (i) En primer lugar se desarrolla una etapa de selección de características

basada en la eliminación recursiva de características por medio del algoritmo de *Random Forest* que permite determinar para qué conjunto y número de variables se consiguen obtener las mejores prestaciones. Esta técnica de selección de características es contrastada con tres técnicas diferentes de filtrado usadas habitualmente para el ordenamiento de características como son el criterio de Ganancia de Información, análisis de varianza (ANOVA) y el algoritmo *Relief-F*. (ii) Con el objetivo de reducir el sesgo del clasificador en su etapa de entrenamiento, se equilibra el conjunto de datos con una técnica denominada *Synthetic Minority Oversampling TEchnique* (SMOTE) la cual genera observaciones sintéticas adicionales que permiten equilibrar las clases del conjunto de entrenamiento. (iii) Finalmente, se propone un novedoso algoritmo de aprendizaje basado en técnicas de *Adaptive Boosting* (AdaBoost) cuya principal ventaja es que puede ser usado en conjuntos de datos de diferentes casos sin modificar sus parámetros de ajuste.

Ambas metodologías han sido validadas experimentalmente con datos de un MI alimentado bajo diferentes fuentes de alimentación para dos niveles diferentes de carga y sometido a un fallo de barra rota con cuatro severidades.

Thesis summary

Induction motors (IMs) driven systems consume most of the electric energy in the industrial sector. Mechanical problems, which *a priori* do not lead to catastrophic faults, such as rotor faults occurring within the squirrel cage of an IM, may develop over time and may cause malfunctioning in some other components of the machine, such as a stator fault. This fact may result in high operational risks regarding the personnel security and their costs associated to production loss. Consequently, to reduce these drawbacks and to improve availability, reliability and performance of the machines, it is necessary to develop diagnosis methodologies to perform early detection of incipient faults in the rotor bars. Motor Current Signature Analysis (MCSA) has been established as one of the main condition monitoring magnitudes to carry out a non-invasive diagnosis of rotor faults. However, the wide variety of inverter-powered industrial motors along with the limited and imbalanced amount of data normally available to construct a diagnostic tool, where the healthy class greatly outnumber the faulty one, complicate the intelligent fault diagnosis under these troublesome conditions. To resolve these issues, an insensitive to the data balance and robust diagnosis methodology has been developed to deal with these problems.

The first methodology is aimed at reducing the uncertainty in the localization of the rotor bar fault frequencies through the transform known Multiple Signal Classification (MUSIC) for later quantify the fault severity by means of the Fast Fourier Transform (FFT). This allows that by combining MUSIC with the FFT, the severity of intermediate faults to the broken rotor bar in motors fed by an inverter can be quantified. The second methodology is a new proposal that addresses automatic fault diagnosis when the starting dataset is small and imbalanced. The methodology consists of the following stages: (i) First, a feature selection stage is developed based on the recursive feature elimination by means of the Random Forest algorithm, which allows to determine for which set and number of variables the best performance is achieved. This feature selection technique is contrasted with three different filtering techniques commonly used for feature ranking as Information Gain, Analysis of Variance

(ANOVA) and Relief-F algorithm. (ii) In order to reduce classifier bias at the training stage, the dataset is balanced with a technique called Synthetic Minority Oversampling TEchnique (SMOTE), which generates additional synthetic observations that allow the balance of classes belonging to the training set. (iii) Finally, a novel learning algorithm based on Adaptive Boosting techniques (AdaBoost) whose main advantage is that it can be used in datasets of different cases without modifying its adjustment parameters is proposed.

Both methodologies have been experimentally validated with data from an IM fed under different power supplies for two different load levels, subjected to four broken rotor bar severities.

Palabras clave (*Keywords*)

- Motor de Inducción; Induction motor
- Diagnóstico; Diagnosis
- Fallos de rotor; Rotor faults
- Datos pequeños y desequilibrados; Imbalanced small data
- Inversores; Inverters
- Análisis espectral; Spectral analysis
- Algoritmos de clasificación; Classification algorithms
- Análisis en estado estable; Steady-State analysis
- Selección de características; Feature selection

Índice

Agradecimientos institucionales	II
Resumen	V
Thesis summary	VII
Lista de figuras	XIX
Lista de tablas	XXII
1. Introducción.	1
1.1. Motivación y descripción general del problema.	1
1.2. Objetivos.	5
1.2.1. Objetivos generales.	5
1.2.2. Objetivos específicos.	5
1.3. Metodología desarrollada.	6
1.4. Estructura de la tesis.	8
2. Antecedentes.	10
2.1. Descripción de los defectos de los MI.	11
2.1.1. Fallos en el estátor.	13
2.1.2. Fallos de excentricidad.	14
2.1.3. Fallos en los Rodamientos.	15
2.1.4. Fallos en el rotor.	18
2.2. Magnitudes empleadas para la detección de anomalías en el motor.	22
2.2.1. Técnicas basadas en modelos del motor.	22
2.2.2. Análisis de vibraciones.	22

2.2.3.	Análisis del flujo magnético.	23
2.2.4.	Medida del par.	24
2.2.5.	Potencia instantánea.	25
2.2.6.	Tensiones residuales a la desconexión.	25
2.2.7.	Emisiones acústicas y sonido.	26
2.2.8.	Análisis por termografía.	26
2.2.9.	Análisis de la corriente estatórica.	27
2.3.	Técnicas de detección.	27
2.3.1.	Detección en régimen estacionario.	28
2.3.1.1.	Vector extendido de Park.	28
2.3.1.2.	Mapas de colores.	29
2.3.1.3.	Técnicas en el dominio del tiempo.	29
2.3.1.4.	La Transformada Rápida de Fourier (FFT).	29
2.3.1.5.	Análisis de la señal analítica.	31
2.3.1.6.	Transformada MUltiple SIgnal Classification (MUSIC).	33
2.3.1.7.	Análisis del orden armónico.	35
2.3.2.	Detección en régimen transitorio.	36
2.4.	Técnicas inteligentes para diagnóstico y aprendizaje estadístico.	37
2.4.1.	Redes Neuronales Artificiales o <i>Artificial Neural Networks (ANN)</i>	39
2.4.2.	Lógica difusa o <i>Fuzzy Logic</i>	40
2.4.3.	Sistemas expertos o <i>Expert Systems</i>	40
2.4.4.	Máquinas de Soporte Vectorial o <i>Support Vector Machines (SVM)</i>	41
2.4.5.	Análisis Lineal Discriminante o <i>Linear Discriminant Analysis (LDA)</i>	42
2.4.6.	K-vecinos más cercanos o <i>K-Nearest Neighbors (K-NN)</i>	43
2.4.7.	Árboles de decisión o <i>Decision Trees (DT)</i>	44
2.4.8.	Otras técnicas de diagnóstico de fallos.	45
2.5.	Oportunidades y conclusiones.	46
2.5.1.	Desarrollo de características para el análisis de señales ruidosas.	46
2.5.2.	Evaluación y diseño de la herramienta de diagnóstico en contextos reales.	46
2.5.2.1.	Aprovechamiento de la información ante desequilibrios de clase.	47
2.5.2.2.	Necesidad de evaluar correctamente las prestaciones de los algoritmos.	47

3. Marco teórico.	49
3.1. Alimentación de un MI por inversor.	49
3.1.1. Estructura de un inversor.	50
3.1.2. Inversor de tensión de dos niveles.	51
3.1.3. Contenido armónico de la señal de tensión de salida.	54
3.1.4. Otro contenido armónico.	57
3.1.5. Efectos del uso del inversor en el sistema motor más inversor.	58
3.1.5.1. Alteración de los patrones de fallo por el uso de inversor.	59
3.2. Tratamiento de la señal con alto contenido armónico.	61
3.2.1. Descripción de los filtros FIR.	64
3.2.2. Diseño de un filtro FIR de rizado uniforme óptimo.	66
3.2.3. Filtrado paso de banda de las frecuencias de interés.	68
3.3. Patrones característicos de asimetría rotórica.	69
3.3.1. Patrones en el dominio del tiempo de la onda de corriente.	69
3.3.2. Patrones en el dominio de la frecuencia.	72
3.3.2.1. Cuantificadores de la severidad del fallo.	73
3.4. Aspectos a tener en cuenta para el diagnóstico.	76
3.4.1. Evaluación del comportamiento del clasificador.	77
3.4.1.1. Métricas y curvas de evaluación.	78
3.4.1.2. Métodos de estimación del error.	83
3.4.1.3. Pruebas de significancia estadística.	85
3.5. Conclusiones del capítulo.	85
4. Metodología.	86
4.1. Variables de seguimiento de la condición en régimen estacionario.	88
4.2. Metodología de análisis espectral de alta resolución para la detección de fallo incipiente.	89
4.3. Métodos de selección de variables y características.	96
4.3.1. Métodos de filtrado para la selección de características.	98
4.3.1.1. Métodos de filtrado basados en el análisis de correlación.	99
4.3.1.2. Criterio de la ganancia de información (<i>Information-Gain</i>).	99
4.3.1.3. Análisis de Varianza o <i>ANalysis of VAriance</i> (ANOVA).	100
4.3.1.4. Algoritmo <i>Relief-F</i>	101
4.4. Selección de características con <i>Random Forest</i> por eliminación recursiva de características.	102

4.5. Propuesta metodológica para diagnóstico de motores con conjuntos de datos pequeños y clases desequilibradas.	108
4.5.1. Técnicas de muestreo en condiciones de desequilibrio de clases.	108
4.5.2. <i>Synthetic Minority Over-sampling Technique (SMOTE)</i>	109
4.5.3. Clasificación con técnicas de <i>Adaptive Boosting (AdaBoost)</i>	112
4.5.4. Integración de las técnicas anteriores para construir la herramienta de diagnóstico.	116
5. Resultados.	118
5.1. Diseño del conjunto de ensayos.	118
5.2. Magnitudes monitorizadas.	120
5.3. Ensayos realizados en el laboratorio.	120
5.4. Elementos que componen el banco de ensayos.	121
5.5. Resultados de la metodología combinada MUSIC-FFT para la detección de fallo incipiente.	122
5.6. Procesamiento de las pruebas y extracción de patrones.	127
5.7. Análisis de Bandas de Frecuencia.	129
5.7.1. Análisis de las bandas laterales de la componente fundamental.	129
5.7.2. Análisis de los indicadores basados en las bandas laterales armónicas superiores al fundamental.	132
5.8. Resultados de la selección de características.	137
5.8.1. Resultados de la etapa de filtrado.	137
5.8.2. Resultados de la selección recursiva de características con <i>Random Forest</i>	145
5.9. Resultados de la herramienta de diagnóstico.	151
5.9.1. Resultados de equilibrar los datos de entrenamiento con SMOTE.	152
5.9.2. Resultados de <i>AdaBoost</i> con datos conjuntos de fuentes de alimentación.	156
5.9.2.1. Resultados de <i>AdaBoost</i> con clasificación multiclase.	162
5.9.2.2. Resultados de clasificación biclase con <i>AdaBoost</i> para diferentes IR.	162
5.9.2.3. Estudio para conjuntos de datos de diferentes tamaños.	164
5.9.3. Comparación de <i>AdaBoost</i> con otros clasificadores en clasificación biclase.	166
5.10. Conclusiones del capítulo.	198
6. Conclusiones y aportaciones.	201
6.1. Conclusiones técnicas del trabajo.	201

6.2. Listado de publicaciones que acompañan a esta tesis.	206
6.2.1. Artículos publicados.	206
6.2.2. Ponencias en congresos internacionales.	207
6.3. Prospectivas.	207
6.3.1. Prospectiva tecnológica.	207
6.3.2. Prospectiva personal.	209
7. Conclusions and contributions	210
7.1. Technical conclusions of the work	210
7.2. List of publications that accompany this thesis.	215
7.2.1. JCR peer-review publications	215
7.2.2. Oral presentations and peer-review publications in International Con- ferences	215
7.3. Foresights	216
7.3.1. Technological foresight	216
7.3.2. Personal foresight	218
A. Equipos empleados en el desarrollo experimental.	219
A.1. Motor de inducción.	219
A.2. Fuentes de suministro del motor.	220
A.2.1. Inversores	220
A.2.2. Alimentación de red.	224
A.3. Freno y unidad de control.	224
A.4. Sensores	225
A.4.1. Transductores de corriente.	226
A.4.2. Transductores de tensión.	228
A.5. Sistema de adquisición de datos.	229
A.6. Ordenador y software empleado.	230
B. Características de los ensayos realizados.	232
C. Resultados adicionales.	238
C.1. Resumen estadístico de las variables empleadas.	238
Bibliografía	257

Índice de figuras

1.1. Esquema de la herramienta de diagnóstico a desarrollar.	3
2.1. Esquema de las magnitudes, tipos de fallo y técnicas de detección más estudiadas en la literatura.	11
2.2. Despiece de un MI de jaula de ardilla.	12
2.3. Corte de un MI de jaula de ardilla.	13
2.4. Clasificación de los fallos más comunes en máquinas asíncronas.	13
2.5. Estátor de un MI.	14
2.6. Consecuencias críticas de los fallos de excentricidad.	15
2.7. Tipos de excentricidad en un MI.	16
2.8. Componentes de un rodamiento.	17
2.9. Desarrollo típico de una grieta en la jaula.	19
2.10. Grietas y separación de la unión barra-anillo en un rotor de cobre soldado.	19
2.11. Protrusión en la jaula del rotor en un motor.	20
2.12. Frecuencia de propagación de un fallo de barra rota.	22
2.13. Ilustración con la proyección de la HT, la señal real, la señal analítica y el fasor en el plano complejo.	32
2.14. Evolución histórica de las técnicas de detección y diagnóstico de fallos.	38
3.1. Accionamiento de un MI con inversor.	51
3.2. Formas de onda de un esquema PWM senoidal.	53
3.3. Tensiones de línea generadas según un esquema PWM senoidal.	54
3.4. Tensión de línea y fase-neutro (neutro real de la carga) para una carga inductiva.	57
3.5. Contenido armónico de la tensión de línea.	57
3.6. Inyección del tercer armónico en onda moduladora.	58
3.7. Contenido armónico de la tensión de línea en alimentación directa de red.	60

3.8. Contenido armónico de la tensión de línea en alimentación con variador.	61
3.9. Diagrama de bloque básico de un filtro digital.	62
3.10. Diagrama de flujo del algoritmo Parks-McClellan.	68
3.11. Espectro de la corriente de fase de un MI con seis barras rotas.	75
3.12. Ejemplo de curva ROC para dos clasificadores.	81
3.13. Ejemplo de curva Precision-Recall para dos clasificadores.	82
4.1. Diagrama de bloques de las metodologías propuestas.	87
4.2. Diagrama de bloques de la metodología propuesta MUSIC-FFT.	90
4.3. Influencia de los tiempos de adquisición para la localización de la frecuencia con MUSIC.	92
4.4. Influencia de los tiempos de adquisición para la cuantificación del fallo con la FFT.	93
4.5. Diagrama de flujo para estimar los tres órdenes de la propuesta basada en MUSIC.	95
4.6. Ilustración de la generación bi-dimensional de nuevas observaciones con SMOTE.	112
4.7. Construcción de la ensamble de clasificadores con AdaBoost.	113
4.8. Ilustración gráfica de la construcción del clasificador <i>AdaBoost</i>	115
4.9. Metodología de diagnóstico propuesta para conjuntos de datos desequilibrados.	117
5.1. Estados del rotor según el taladro realizado.	119
5.2. Esquema de los ensayos realizados.	120
5.3. Banco de ensayos experimental.	121
5.4. Ejemplo de dispersión de los tres órdenes de MUSIC fijados para un conjunto de señales experimentales.	122
5.5. Espectros FFT y MUSIC para los suministros ABB y WEG del motor.	125
5.6. Espectros FFT y MUSIC para los suministros TM y de línea del motor.	126
5.7. Gráfico de correlación de las variables procesadas para el caso de alimentación de red.	128
5.8. Diagrama de dispersión del LSH y RSH en función del deslizamiento. Alimentación de red.	130
5.9. Diagrama de dispersión del LSH y RSH en función del deslizamiento. Alimentación ABB.	131
5.10. Diagrama de dispersión del LSH y RSH en función del deslizamiento. Alimentación Allen Bradley.	133

5.11. Diagrama de dispersión del LSH y RSH en función del deslizamiento. Alimentación Telemecanica.	134
5.12. Análisis de las características construidas con ratios de armónicos superiores al fundamental. Alimentación de red.	135
5.13. Análisis de las características construidas con ratios de armónicos superiores al fundamental. Alimentación ABB.	136
5.14. Ordenamiento de las características con los métodos de filtrado en alimentación de red.	138
5.15. Ordenamiento de las características con los métodos de filtrado. Alimentación inversor ABB.	140
5.16. Ordenamiento de las características con los métodos de filtrado. Alimentación inversor Allen Bradley.	142
5.17. Ordenamiento de las características con los métodos de filtrado. Alimentación inversor Telemecanique.	144
5.18. Tamaño del conjunto de características seleccionadas con RF-RFE (5-repeated 10-fold CV). Alimentación de red	146
5.19. Tamaño del conjunto de características seleccionadas con RF-RFE (5-repeated 10-fold CV). Inversor ABB.	147
5.20. Tamaño del conjunto de características seleccionadas con RF-RFE (5-repeated 10-fold CV). Inversor Allen Bradley.	149
5.21. Tamaño del conjunto de características seleccionadas con RF-RFE (5-repeated CV). Inversor Telemecanique.	149
5.22. Aplicación de SMOTE para $IR = 10$. Se muestra el LSH y RSH para alimentación de red.	153
5.23. Aplicación de SMOTE para $IR = 5$. Se muestra el LSH y RSH para alimentación de red.	154
5.24. Aplicación de SMOTE para $IR = 10$. Se muestra el LSH y RSH para alimentación por inversor ABB.	155
5.25. Aplicación de SMOTE para $IR = 5$. Se muestra el LSH y RSH para alimentación por inversor ABB.	157
5.26. Aplicación de SMOTE para $IR=10$. Se muestra el LSH y RSH para alimentación por inversor Allen Brad.	158
5.27. Aplicación de SMOTE para $IR = 5$. Se muestra el LSH y RSH para alimentación por inversor Allen Brad.	159

5.28. Aplicación de SMOTE para $IR = 10$. Se muestra el LSH y RSH para alimentación por inversor Telemecanique.	160
5.29. Aplicación de SMOTE para $IR = 5$. Se muestra el LSH y RSH para alimentación por inversor Telemecanique.	161
5.30. Curvas ROC de los clasificadores con agrupación OOA.	167
5.31. Comparación de clasificadores con datos de red tras aplicar SMOTE ($IR = 10$).175	
5.32. Comparación de clasificadores con datos de red tras aplicar SMOTE ($IR = 5$). 176	
5.33. Comparación de clasificadores con datos de inversor ABB tras aplicar SMOTE ($IR = 10$).	183
5.34. Comparación de clasificadores con datos de inversor ABB tras aplicar SMOTE ($IR = 5$).	184
5.35. Comparación de clasificadores con datos de inversor Allen Brad. tras aplicar SMOTE ($IR = 10$).	190
5.36. Comparación de clasificadores con datos de inversor Allen Brad. tras aplicar SMOTE ($IR = 5$)	191
5.37. Comparación de clasificadores con datos de inversor TM tras aplicar SMOTE ($IR = 10$).	196
5.38. Comparación de clasificadores con datos de inversor TM tras aplicar SMOTE ($IR = 5$).	197
A.1. Motor ensayado.	219
A.2. Inversor ABB modelo ACS355.	221
A.3. Inversor Allen Bradley modelo PowerFlex 40.	222
A.4. Inversor WEG modelo CFW-11.	223
A.5. Inversor Siemens modelo Micromaster 420.	223
A.6. Inversor Telemecanique modelo Altivar 66.	224
A.7. Freno conectado al motor y unidad de control.	225
A.8. Tarjetas dedicadas con los transductores de efecto Hall (tensión y de corriente).226	
A.9. Transductor de corriente de Honeywell.	226
A.10. Transductor de corriente de LEM.	227
A.11. Transductores de tensión.	228
A.12. Sistema de adquisición de datos de NI.	230
A.13. Ordenador portátil empleado.	231
B.1. Boxplots de las pruebas con los valores de corriente. Motor sano (R1).	232

B.2. Boxplots de las pruebas con los valores de deslizamiento. Motor sano (R1).	233
B.3. Boxplots de las pruebas con los valores de corriente. Severidad R2.	233
B.4. Boxplots de las pruebas con los valores de deslizamiento. Severidad R2.	234
B.5. Boxplots de las pruebas con los valores de corriente. Severidad R3.	234
B.6. Boxplots de las pruebas con los valores de deslizamiento. Severidad R3.	235
B.7. Boxplots de las pruebas con los valores de corriente . Severidad R4.	235
B.8. Boxplots de las pruebas con los valores de deslizamiento. Severidad R4.	236
B.9. Boxplots de las pruebas con los valores de corriente. Severidad R5.	236
B.10.Boxplots de las pruebas con los valores de deslizamiento. Severidad R5.	237

Índice de tablas

3.1. Matriz de confusión.	78
4.1. Características espectrales obtenidas de la corriente estatórica con la FFT. .	89
4.2. Análisis de las ventajas y desventajas de los diferentes métodos de selección de características.	107
5.1. Valores de detectabilidad promedio con MUSIC-FFT.	124
5.2. Características más informativas según los métodos de filtrado (Umbral de 7 características). Alimentación de red.	139
5.3. Características más informativas según los métodos de filtrado (Umbral de 7 características). Inversor ABB.	139
5.4. Características más informativas según los métodos de filtrado (Umbral de 7 características). Inversor Allen Bradley.	143
5.5. Características más informativas según los métodos de filtrado (Umbral de 7 características). Inversor Telemecanique.	145
5.6. Características seleccionadas con RF-RFE. Alimentación de red.	147
5.7. Características seleccionadas con RF-RFE. Inversor ABB.	148
5.8. Características seleccionadas con RF-RFE. Inversor Allen Bradley.	150
5.9. Características seleccionadas con RF-RFE. Inversor Telemecanique.	151
5.10. Descripción de los conjuntos de datos.	162
5.11. MC (%) y métricas de <i>AdaBoost</i> para el caso multiclase con SMOTE ($IR = 2$) y sin SMOTE.	163
5.12. Métricas de performance para el caso desequilibrado sin aplicar SMOTE. . .	164
5.13. Métricas de performance para el caso equilibrado con SMOTE.	165
5.14. Métricas de performance para datos equilibrados con SMOTE para conjuntos de diferentes tamaños.	166

5.15. Resultados de la evaluación de los clasificadores para la severidad R2. Alimentación de RED $IR = 10$	171
5.16. Resultados de la evaluación de los clasificadores para la severidad R3. Alimentación de RED $IR = 10$	172
5.17. Resultados de la evaluación de los clasificadores para la severidad R4. Alimentación de RED $IR = 10$	172
5.18. Resultados de la evaluación de los clasificadores para la severidad R5. Alimentación de RED $IR = 10$	173
5.19. Resultados de la evaluación de los clasificadores para la severidad R2. Alimentación de RED $IR = 5$	173
5.20. Resultados de la evaluación de los clasificadores para la severidad R3. Alimentación de RED $IR = 5$	174
5.21. Resultados de la evaluación de los clasificadores para la severidad R4. Alimentación de RED $IR = 5$	174
5.22. Resultados de la evaluación de los clasificadores para la severidad R5. Alimentación de RED $IR = 5$	177
5.23. Resultados de la evaluación de los clasificadores para la severidad R2. Inversor ABB $IR = 10$	178
5.24. Resultados de la evaluación de los clasificadores para la severidad R3. Inversor ABB $IR = 10$	179
5.25. Resultados de la evaluación de los clasificadores para la severidad R4. Inversor ABB $IR = 10$	179
5.26. Resultados de la evaluación de los clasificadores para la severidad R5. Inversor ABB $IR = 10$	180
5.27. Resultados de la evaluación de los clasificadores para la severidad R2. Inversor ABB $IR = 5$	180
5.28. Resultados de la evaluación de los clasificadores para la severidad R3. Inversor ABB $IR = 5$	181
5.29. Resultados de la evaluación de los clasificadores para la severidad R4. Inversor ABB $IR = 5$	181
5.30. Resultados de la evaluación de los clasificadores para la severidad R5. Inversor ABB $IR = 5$	182
5.31. Resultados de la evaluación de los clasificadores para la severidad R2. Inversor Allen Brad. $IR = 10$	185

5.32. Resultados de la evaluación de los clasificadores para la severidad R3. Inversor Allen Brad. $IR = 10$	186
5.33. Resultados de la evaluación de los clasificadores para la severidad R4. Inversor Allen Brad. $IR = 10$	186
5.34. Resultados de la evaluación de los clasificadores para la severidad R5. Inversor Allen Brad. $IR = 10$	187
5.35. Resultados de la evaluación de los clasificadores para la severidad R2. Inversor Allen Brad. $IR = 5$	187
5.36. Resultados de la evaluación de los clasificadores para la severidad R3. Inversor Allen Brad. $IR = 5$	188
5.37. Resultados de la evaluación de los clasificadores para la severidad R4. Inversor Allen Brad. $IR = 5$	188
5.38. Resultados de la evaluación de los clasificadores para la severidad R5. Inversor Allen Brad. $IR = 5$	189
5.39. Resultados de la evaluación de los clasificadores para la severidad R2. Inversor Telemecanique $IR = 10$	192
5.40. Resultados de la evaluación de los clasificadores para la severidad R3. Inversor Telemecanique $IR = 10$	193
5.41. Resultados de la evaluación de los clasificadores para la severidad R4. Inversor Telemecanique $IR = 10$	193
5.42. Resultados de la evaluación de los clasificadores para la severidad R5. Inversor Telemecanique $IR = 10$	194
5.43. Resultados de la evaluación de los clasificadores para la severidad R2. Inversor Telemecanique $IR = 5$	194
5.44. Resultados de la evaluación de los clasificadores para la severidad R3. Alimen- tación de RED $IR = 5$	195
5.45. Resultados de la evaluación de los clasificadores para la severidad R4. Inversor Telemecanique $IR = 5$	195
5.46. Resultados de la evaluación de los clasificadores para la severidad R5. Inversor Telemecanique $IR = 5$	198
C.1. Resumen estadístico de las variables usadas para el análisis equilibrado. . . .	239

Capítulo 1

Introducción.

En este capítulo, se desarrolla una introducción con los principales motivos (1.1), exponiendo la casuística e importancia del problema que se trata de resolver. Finalmente, los objetivos que se persiguen (1.2), son claramente definidos para conformar la metodología más adecuada (1.3) de este trabajo original de investigación.

1.1. Motivación y descripción general del problema.

Las máquinas eléctricas rotativas forman un papel esencial en el desarrollo industrial del siglo XXI. La presencia de una gran variedad y cantidad de motores eléctricos en la industria representa un desafío para asegurar una operación fiable de estos sistemas. Dentro del equipamiento industrial, uno de los elementos más importantes es el motor de inducción (MI) o asíncrono. Este tipo de motor eléctrico es el principal convertidor de energía eléctrica en mecánica en la industria. Aproximadamente el 90 % de los motores industriales son de este tipo, llegando a consumir casi el 50 % de la energía producida en una nación industrializada [1]. A pesar de que este tipo de convertidor electromecánico asume un protagonismo notable debido a su robustez, fiabilidad, eficiencia y, facilidad de regulación de velocidad, una parada inesperada de estos elementos, puede acarrear consecuencias inmensurables en aquellas industrias o procesos donde opera. Por ello, uno de los factores que ayudan a aumentar la competitividad de una industria moderna es la reducción de costes, entre los que se encuentran los asociados al mantenimiento [2]. El MI está sujeto a desgastes, fallos de montaje, tolerancias, etc., lo que puede acabar provocando un fallo prematuro. También es importante tener en cuenta la forma de regular el régimen de operación de estos motores, muy crítico en aplicaciones como: tracción ferroviaria [3], sistemas de bombeo, así como he-

herramientas de mecanizado, sólo por citar algunos. El motor asíncrono se alimenta de red en aplicaciones de velocidad fija y a través de un inversor en aplicaciones de velocidad variable o que requieran un control de par. Además, en aplicaciones donde el flujo de energía eléctrica procede de fuentes de energía renovable, tales como la energía solar fotovoltaica, el uso de inversores toma un papel fundamental para el suministro de potencia de estos sistemas dentro de los cuales, el MI es un elemento fundamental. Si el motor está bien seleccionado según los requerimientos de la aplicación, su tasa de fallos debería ser baja y su vida útil larga. Sin embargo, debido a defectos de fabricación, especificaciones incorrectas, ciclos de trabajo no adecuados, montaje incorrecto, etc., esta máquina puede estar sujeta a fallos provocados por el estrés térmico, eléctrico y mecánico, así como a los esfuerzos de fatiga al que se ve sometido el material. Entre los elementos que pueden fallar se pueden citar el rotor, rodamientos, eje, bobinado del estator, etc. La importancia del fallo en la aplicación industrial depende de muchos factores:

- Importancia y/o criticidad del motor en el sistema de producción.
- Accesibilidad del motor para la reparación.
- Existencia de stocks.
- Tipo de mantenimiento.

Es cierto que, bajo ciertos tipos de fallo prácticamente todos salvo el cortocircuito del estator y algunos fallos mecánicos asociados al eje, el motor puede seguir funcionando, aparentemente de forma correcta [4]. Pero en algunos casos, la existencia del fallo afecta a la generación del par o produce oscilaciones de velocidad que, por ejemplo, pueden afectar al producto final en un ciclo de mecanizado o al confort en una aplicación de tracción. Por lo tanto, para su detección es necesario desarrollar un sistema de diagnóstico [2]. Las prestaciones y orientación del sistema de diagnóstico dependerán del mantenimiento requerido por la aplicación y de la importancia del fallo. Es decir, en algunos casos será necesario diagnosticar el fallo incipiente, mientras que en otros basta con el diagnóstico de un fallo desarrollado, pero siempre antes de que el fallo derive en uno catastrófico, que podría suponer la destrucción total del motor, acarrear consecuencias para el resto del sistema productivo o elementos en la cadena cinemática, e incluso puede poner en riesgo la vida de las personas. Por consiguiente, la herramienta de diagnóstico a desarrollar (Figura 1.1), surge de la necesidad de reducir el impacto, los costes propios de reparación y sustitución de la maquinaria entre otros [5].

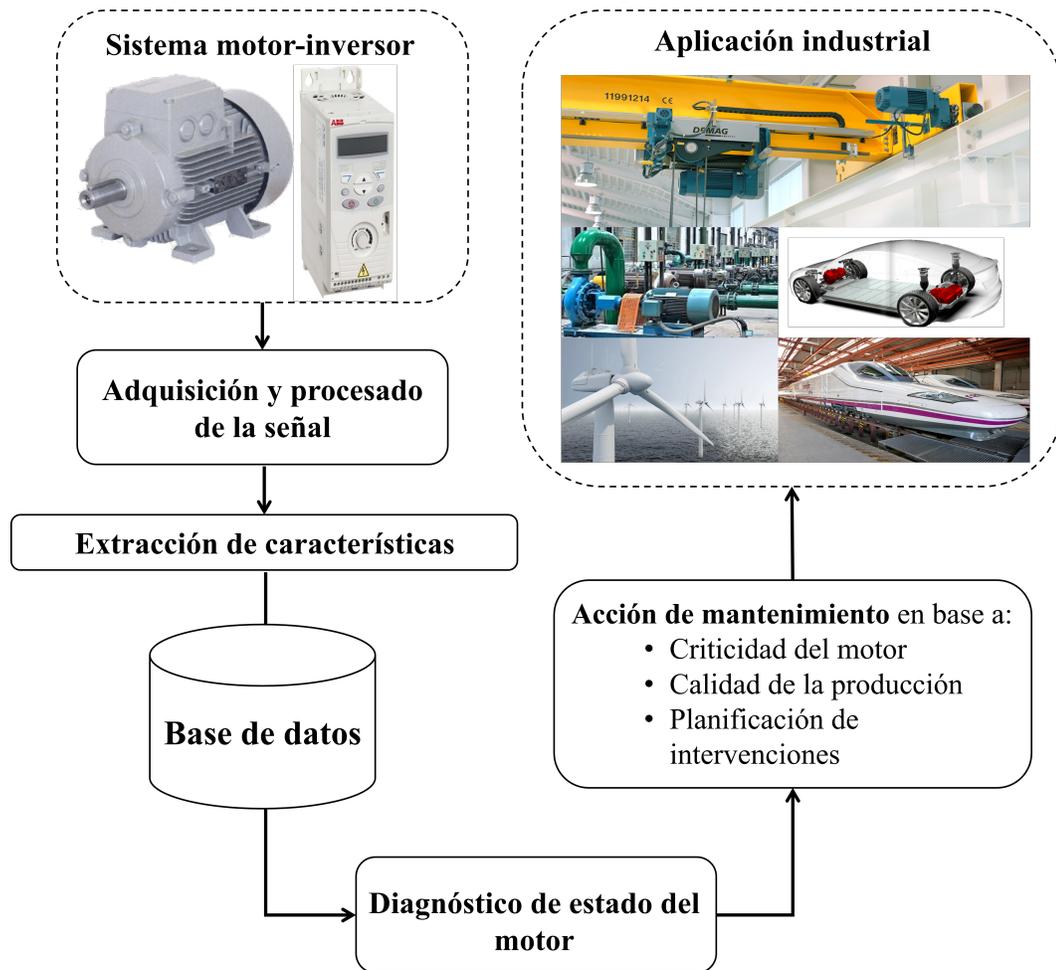


Figura 1.1: Esquema del entorno en el que se encuentra contemplada la herramienta de diagnóstico a desarrollar en la presente tesis doctoral.

Muchas técnicas de mantenimiento están basadas en la monitorización de la condición donde se adquiere y procesa la señal de interés [6–8]. Claro está que, ciertas magnitudes físicas que permiten la monitorización e instrumentación del funcionamiento de la máquina, presentan dificultades en su empleo práctico. Por ejemplo, existen métodos invasivos que requieren realizar paradas programadas de la máquina para su observación [9], a diferencia de los métodos no invasivos. Durante las últimas décadas, la técnica de monitorización que se ha ido imponiendo ha sido el análisis de la corriente estática, conocida como *Motor Current Signature Analysis (MCSA)*. Una de las ventajas por las que ha prevalecido este análisis para fines de diagnóstico, es por su facilidad de adquisición como magnitud a monitorizar sin que

influyan las características del entorno donde opera la máquina [10], así como por su facilidad de implementación en sistemas remotos como, por ejemplo, en aplicaciones de transporte [3]. Tanto es así que, este tipo de técnicas han sido implementadas como métodos de detección de fallos en el rotor en aplicaciones como el coche eléctrico o los vehículos híbridos [11]. En la señal de la corriente estatórica, aparecen componentes armónicas, que resultan ser más notorias a medida que el fallo se va desarrollando. Por otro lado, la captura de información de la máquina por medio de sensores permite el análisis y estudio de patrones que pueden ser usados para la construcción de herramientas de monitorización por medio de técnicas de aprendizaje estadístico o minería de datos [12, 13]. Sin embargo, la aparición o facilidad de apreciación de estas componentes, se debe fundamentalmente al tipo de suministro de energía con el que el motor es alimentado, así como a las particularidades de la carga [9]. Por lo que, un MI con necesidad de regulación de velocidad, desafortunadamente lleva asociado un convertidor de frecuencia, también conocido como inversor, que dificulta la extracción de patrones útiles para un diagnóstico de fallos basado en MCSA [14–16].

En la literatura especializada se pueden encontrar diferentes herramientas construidas para el diagnóstico de motores de inducción. Normalmente, estas técnicas sólo están validadas en motores alimentados desde la red eléctrica [17]. El tipo de fallos que cubren es extenso, y en ocasiones son capaces de diagnosticar o distinguir entre diversos tipos de fallos [18]. Si bien es cierto que muy pocos trabajos están realmente orientados al mantenimiento y no son lo suficientemente sensibles para detectar y diagnosticar un fallo incipiente antes de que derive en un fallo catastrófico [4]. Los indicadores de fallo empleados suelen ser los definidos por los modelos físicos existentes [19]. Sin embargo, existen otros trabajos que emplean señales discretas de la alimentación del motor e incluso algunos autores emplean señales de vibración para obtener información relacionada con la condición del motor por medio de variables estadísticas [20–22]. Algunos trabajos ya emplean técnicas más avanzadas para la selección de los patrones de fallo [13, 23], pero sin embargo no se cuida la construcción y estructura del conjunto de datos de entrenamiento. Desde un punto de vista matemático, el conjunto de datos debería ser lo más grande posible y con las distintas clases a evaluar equilibradas. En la práctica, el conjunto de datos suele ser muy pequeño y con una distribución entre clases muy desequilibrada hacia la clase sana. En los trabajos de investigación actualmente publicados, normalmente los datos proceden de ensayos de laboratorio, donde se simula el fallo. El número de datos correspondientes a las clases que representan dicho fallo suele ser del mismo orden de magnitud que los datos correspondientes al motor sano. Además, en pocos casos se considera el fallo incipiente. Los datos empleados para caracterizar el fallo corresponden a severidades

muy altas, por lo que su detección resulta más sencilla. En estos casos, el conjunto de datos suele ser de un tamaño medio y con las clases relativamente equilibradas. Sin embargo, esta forma de trabajar dista de las condiciones reales encontradas en la industria y hace dudar de que las prestaciones de estos sistemas de diagnóstico se acerquen a la realidad. Además, los trabajos se suelen centrar en un tipo concreto de fallos y suelen estar limitados a un único tipo de alimentación, habitualmente la red, no recogiendo la variabilidad existente en las aplicaciones industriales.

Con estas premisas, esta tesis doctoral trata de desarrollar un sistema de diagnóstico de fallos incipientes para motores de inducción, alimentados tanto de red como por inversor, basado en un número pequeño de ensayos y con un importante desequilibrio de las clases hacia la clase habitual donde el motor se encuentra en estado sano.

1.2. Objetivos.

En una situación real, debería ser posible obtener un conjunto de medidas muy elevado. También sería probable que ese conjunto de datos tuviera muchas más medidas del sistema sano que con fallo. El conjunto de datos sería muy grande y con un gran desequilibrio hacia la clase que caracteriza el sistema sin fallo. Sin embargo, en la práctica es más probable que el conjunto de datos sea muy pequeño y con una distribución entre clases muy desequilibrada. Teniendo este aspecto presente, los objetivos de esta tesis se exponen a continuación.

1.2.1. Objetivos generales.

Proponer un sistema de diagnóstico de fallos incipientes para motores de inducción alimentados por convertidor que requiera de un número pequeño de ensayos y con un importante desequilibrio de las clases, siendo la más numerosa la correspondiente al motor sano. Además, se realizará un estudio de los patrones o variables más idóneas para su empleo en la etapa de clasificación, para el desarrollo de la herramienta de diagnóstico. Este estudio, deberá ser validado experimental y estadísticamente.

1.2.2. Objetivos específicos.

- Diseñar un banco de pruebas que permita la captura de las señales de corriente del motor alimentado por convertidor y red bajo diferentes condiciones de fallo dentro de las cuales se consideran cuatro estados de fallo de una de las barras del rotor.

- Aplicar las técnicas de procesamiento de la señal más adecuadas en función del tipo de fallo y de las condiciones de operación del motor, estacionario o velocidad variable.
- Identificar nuevos indicadores de fallo sobre la señal transformada que permitan incrementar las prestaciones de la herramienta de diagnóstico para detectar fallos incipientes de motores alimentados por inversor.
- Construir un conjunto de datos de entrenamiento que cumpla las siguientes condiciones:
 - Debe ser pequeño, comparado con la práctica usual en la literatura especializada pero homogéneo acorde al tipo de alimentación y nivel de carga considerado.
 - Debe ser desequilibrado, es decir, contener un mayor número de observaciones correspondientes al motor sano.
- Aplicar técnicas de aprendizaje estadístico que permitan identificar qué características o variables resultan con mayor poder de discriminación para mejorar las prestaciones del clasificador.
- Desarrollar un sistema de diagnóstico para fallos incipientes que emplee un número de muestras limitado y pequeño y con desequilibrio entre las clases. Tendrán que emplearse técnicas estadísticas para tratar lo que en la literatura se denomina *Small Sample Problem* y *Class Imbalance*. También será necesario investigar e implementar el clasificador más adecuado para realizar el diagnóstico.
- Caracterizar las prestaciones del sistema de diagnóstico por medio de técnicas de evaluación apropiadas para estas nuevas características de los datos de diagnóstico. El valor de los resultados diagnósticos está fuertemente influenciado por la precisión diagnóstica. Reducir el número de falsos positivos y falsos negativos puede marcar la diferencia entre un sistema de diagnóstico que es útil respecto de uno que puede resultar inútil.
- Comparar los resultados obtenidos con los mostrados en la literatura especializada.

1.3. Metodología desarrollada.

La presente tesis doctoral se ha desarrollado durante un periodo de trabajo conjunto entre el grupo de investigación HSPdigital de la Universidad de Guanajuato (México) y el Departamento de Ingeniería Eléctrica de la Universidad de Valladolid (España). Ambos grupos han llevado a cabo trabajos en la detección y diagnóstico de fallos tempranos en

máquinas eléctricas rotativas. Los resultados más favorables se han obtenido particularmente con el empleo y análisis de la corriente de alimentación.

La metodología de diagnóstico que se presenta en la siguiente tesis doctoral abarca principalmente las siguientes etapas:

- *Conocimiento del sistema a diagnosticar.* En esta tesis será el conjunto motor más inversor. El uso de un inversor para alimentar el MI está cada vez más generalizado en la industria por varias razones como son la eficiencia energética, regulación de la velocidad, control de par, etc. Desde un punto de vista de la detección y diagnóstico de fallos, el uso del inversor supone una dificultad añadida por la presencia de ruido en la señal e interarmónicos y subarmónicos que dificultan la observación de los indicadores de fallo. En algunos casos, también se modifica la firma del fallo, con respecto a otros tipos de alimentación.
- *Elección de las variables a monitorizar.* En el caso de un MI las señales suelen ser la corriente eléctrica del estator, el flujo magnético, la temperatura, vibraciones mecánicas y el sonido.
- *Sistema de adquisición de datos con sensores adecuados.* Los parámetros de adquisición, frecuencia y tiempo de muestreo, tienen que ser acordes con la capacidad del sistema de adquisición disponible, pero también con las técnicas de tratamiento de señales que se comentan a continuación.
- *Procesamiento de las señales.* Las señales normalmente se adquieren en el dominio del tiempo, pero para extraer información útil suele ser necesario transformar la señal al dominio de la frecuencia o al dominio tiempo-frecuencia. La técnica de procesamiento de la señal dependerá de la naturaleza de la señal, estacionaria o transitoria, de la detectabilidad del fallo, etc.
- *Extracción de indicadores de fallo.* Después del procesamiento de la señal, es necesario extraer métricas que den información del estado del motor. Es importante que el resultado del procesamiento de la señal se pueda cuantificar si se quiere que el diagnóstico sea automático o realizado por un sistema experto. En algunos casos se pueden extraer un número relativamente elevado de indicadores de fallo. Sin embargo, siempre es necesario aplicar técnicas de reducción o selección de variables, que puedan evaluar la capacidad de discriminación de estas variables en relación al posible estado del motor. Es muy importante eliminar indicadores redundantes, altamente correlacionados

o que aporten poca información, principalmente para evitar esfuerzos computacionales elevados y también para evitar bias o errores en el resultado del sistema de diagnóstico.

- *Construcción del sistema de diagnóstico.* Normalmente se necesita un conjunto de datos relativamente elevado que contenga indicadores relativos a todos los estados que se quieran detectar. En la realidad, resulta complicado construir tal conjunto, puesto que en la práctica se dispondrán de muchos datos del sistema en estado sano y pocos datos del sistema en condiciones de fallo. Disponer de muchos datos del motor con fallo puede ayudar a construir el sistema de diagnóstico, pero introduce un bias que puede dar lugar a una alta tasa de falsos positivos (entendiendo por positivo el fallo). Por el contrario, emplear pocos datos del motor en estado de fallo puede reducir las prestaciones del algoritmo, produciendo una tasa de falsos negativos alta, y por tanto dificultando la detección del fallo. La mayoría de los sistemas de diagnóstico son de tipo supervisado. Es decir, necesitan de un entrenamiento con datos obtenidos previamente. También puede haber sistemas no supervisados, pero son menos comunes.

La metodología propuesta en esta tesis trata de solventar los inconvenientes de los sistemas de diagnóstico actuales que se citan a continuación:

- *Se desaprovecha mucha información.* De cada medida realizada solo se aprovecha parte de la información en forma de indicadores numéricos de fallo. Por ejemplo, cuando la señal monitorizada es la corriente del estátor, varios modelos físicos indican a qué frecuencias pueden aparecer los indicadores de fallo. Es probable que existan más indicadores a otras frecuencias que no son predichas por los modelos. Los modelos físicos ofrecen una representación y explicación de la realidad limitada, debido a la complejidad en su diseño en entornos industriales de este tipo.
- *Tamaño del conjunto de medidas.* Es necesario un número muy elevado de medidas para obtener los datos del conjunto de entrenamiento. El conjunto de datos además debe cubrir todos los estados de fallo que quieren detectarse y diagnosticarse. Siempre es necesario un patrón o firma del sistema sano para poder comparar en el caso de se produzca fallo.

1.4. Estructura de la tesis.

El trabajo de investigación realizado durante estos años, materializado en el presente documento, se expone en el siguiente orden:

- En el capítulo 2 se presentan los antecedentes para dilucidar los motivos que han dado origen a las técnicas, y metodologías que han sido desarrolladas para detectar, diagnosticar o predecir los fallos más comunes en máquinas eléctricas rotativas, también descritos en este capítulo.
- En el capítulo 3 se describe la problemática de localizar defectos en el rotor de motores alimentados por inversor, para proponer y justificar una metodología adecuada para el diagnóstico incipiente de fallos orientada al mantenimiento de máquinas de inducción.
- En el capítulo 4 se presentan las metodologías propuestas en esta tesis. La primera metodología trata de obtener patrones de las señales correspondientes a un fallo incipiente por medio de una aplicación combinada de la transformada MUSIC y la FFT. Posteriormente, se propone una técnica para selección de características tipo envoltorio la cual es comparada con técnicas de selección de características tipo filtro. Finalmente, se desarrolla una metodología que consiste en la aplicación combinada de una técnica de generación de instancias sintéticas (SMOTE) y un clasificador basado en *boosting* conocido como *AdaBoost*, el cual permite solventar la problemática de un diagnóstico basado en pocos datos con clases desequilibradas.
- En el capítulo 5 se muestran los resultados obtenidos por cada metodología propuesta. Para ello, se describen los equipos empleados, ensayos y conjuntos de datos obtenidos durante la realización de las pruebas destructivas realizadas sobre un MI. Uno de los objetivos de este capítulo es establecer y validar experimentalmente las técnicas propuestas.
- Finalmente, en el capítulo 6 se exponen las conclusiones técnicas y se hace un resumen conciso de las aportaciones a las que ha dado lugar esta tesis doctoral; incluyendo las publicaciones científicas derivadas de la misma. Adicionalmente, se exponen las perspectivas tanto personal como tecnológica.

Capítulo 2

Antecedentes.

En este capítulo, se va a exponer una revisión de la situación actual del campo de estudio que trata la detección y diagnóstico de fallos en máquinas eléctricas rotativas de inducción. Es importante notar que se describen técnicas usadas tanto desde el punto de vista de la detección como desde el punto de vista del diagnóstico. En la presente tesis, vamos a referirnos a detección como al descubrimiento de patrones o características que nos ayudan a designar condiciones de funcionamiento anormal de un motor en referencia a su situación de funcionamiento adecuado. Sin embargo, con técnicas de diagnóstico nos referiremos a aquellos conjuntos de técnicas que nos permiten descubrir el estado de la máquina por medio de un conjunto de variables o características que nos aportan información acerca de las condiciones de operación de la misma en base a un conjunto de observaciones disponibles.

Primeramente, se repasa la problemática que acontece en cada una de las partes que componen la máquina de inducción. A continuación, se describen todas las magnitudes físicas empleadas en la literatura y que aportan información relacionada con las averías presentes en la máquina. De este modo, se podrán destacar las ventajas e inconvenientes de cada una de ellas en relación a las metodologías que se pretenden desarrollar. Con ello, se tendrá una visión más general de para qué circunstancias, el empleo de cada una de ellas da lugar o no a una monitorización confiable de la condición de la máquina. Después, se trata una sección que aborda las técnicas de detección desde la perspectiva del régimen de operación de la máquina, profundizando en aquellas técnicas de estado estacionario. Finalmente, se revisan las técnicas inteligentes de diagnóstico actualmente publicadas mostrando los logros conseguidos en el área en este sentido. Para partir de una perspectiva general, en la Fig. 2.1 se muestra de forma esquemática los aspectos más destacados sobre los que se han basado las técnicas propuestas en los últimos años, ya sea atendiendo al tipo de fallo, magnitud de

monitoreo o la técnica de detección de frecuencias.

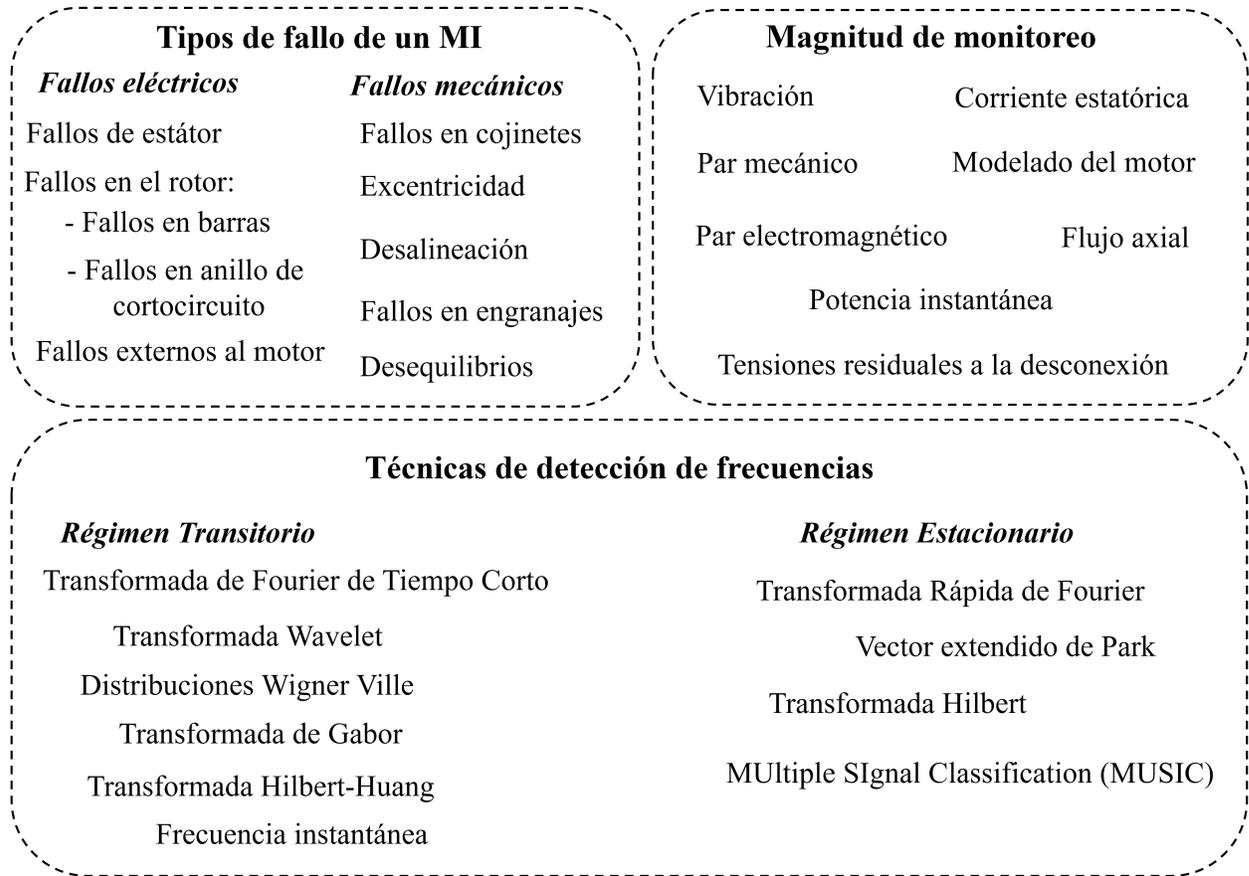


Figura 2.1: Esquema de los trabajos encontrados en la literatura para la detección y diagnóstico de fallos en MIs en relación a: 1) tipo de fallo a detectar, 2) Magnitud a monitorear y, 3) Técnicas de identificación de patrones de fallo en el dominio de la frecuencia.

2.1. Descripción de los defectos de los MI.

Los fallos a los que puede estar sometida una máquina de inducción se pueden clasificar atendiendo a su origen (eléctrico, mecánico, térmico, etc.) o a la parte donde se desarrollan (estátor, rodamientos, rotor, etc.). En las Figs. 2.2 y 2.3, se muestra un despiece y un corte de un MI de jaula de ardilla donde se pueden apreciar los diferentes elementos donde puede acontecer un fallo. El funcionamiento de los motores, como el de los generadores, está descrito básicamente por los mismos principios físicos. Por ello, están sujetos a los mismos tipos de

fallos en general. Como guía del presente estudio, es necesario conocer los defectos que se producen regularmente en máquinas asíncronas. En la literatura, se han realizado varios estudios a gran escala de motores asíncronos con características muy diferentes con el fin de conocer la distribución de los defectos que se producen en estos sistemas [24–26]. Los resultados mostrados por estos estudios se pueden ver en la Fig. 2.4 atendiendo a cuatro categorías: rodamientos, estátor, rotor y otros. Estos estudios estadísticos nos dicen que la mayoría de los fallos se presentan en los rodamientos, en el estátor (principalmente los relacionados con el aislamiento de las bobinas), así como en el rotor en menor medida. Sin embargo, dependiendo de la potencia de los motores, estos datos pueden variar [27]. Esta tesis emplea motores de baja potencia (0.75 kW), los cuales son los que más presencia tienen en la industria y se aborda el fallo del rotor ya que, en su etapa incipiente, es uno de los fallos no catastróficos a los que puede estar sometido un motor de jaula de ardilla y, por tanto, permite evitar consecuencias más severas. No obstante, a continuación, se describen todos los fallos que puede llegar a padecer un MI.

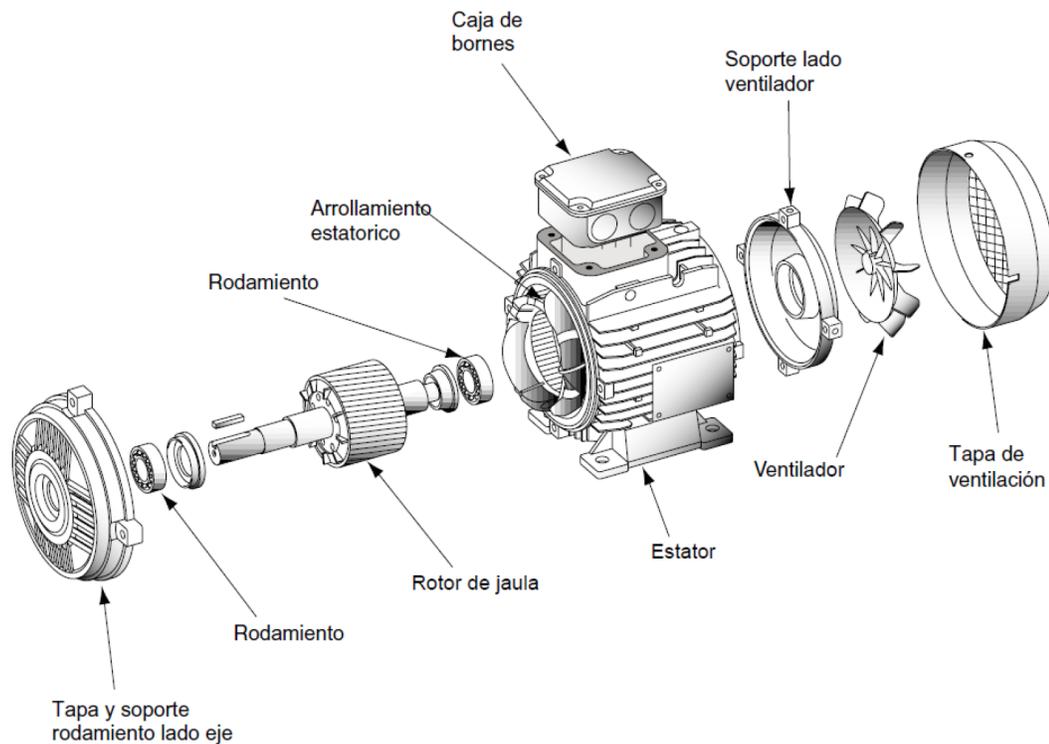


Figura 2.2: Despiece de un MI de jaula de ardilla [28].

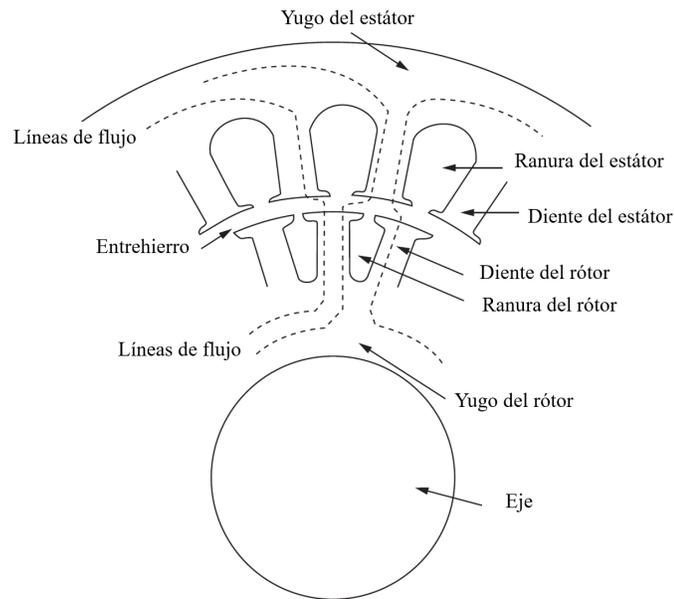


Figura 2.3: Corte de un MI de jaula de ardilla [29].

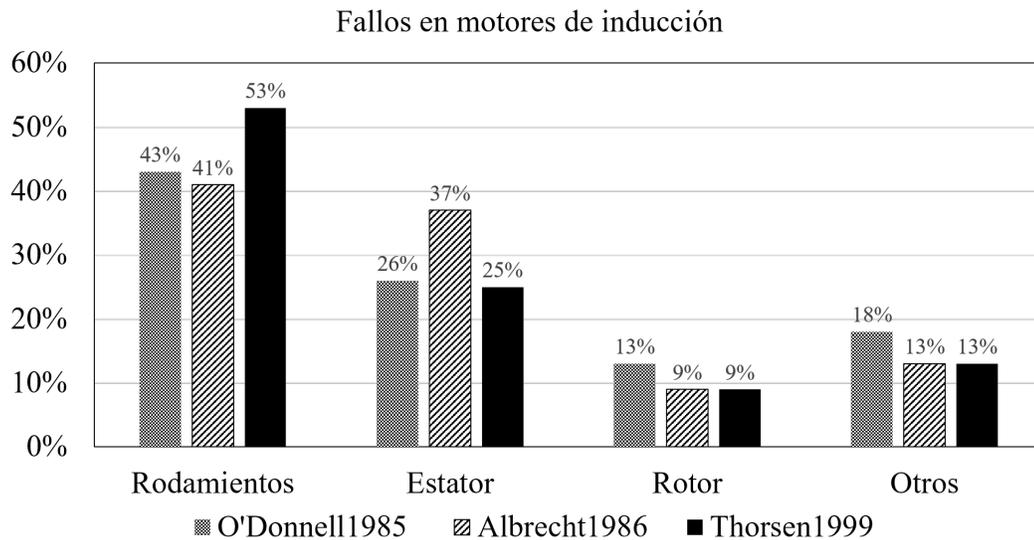


Figura 2.4: Clasificación de los fallos más comunes en máquinas asíncronas según los autores [24–26].

2.1.1. Fallos en el estátor.

La problemática más crítica que se produce en el estátor es la pérdida del aislamiento dieléctrico causada por fallos de origen eléctrico [30]. Un tipo común de fallo en el estátor es la

apertura de una fase, la cual no resulta ser un fallo catastrófico, pero sí provoca una reducción del par. Sin embargo, un fallo crítico son los cortocircuitos entre espiras de una misma fase que pueden llegar a producir un deterioro completo del estátor de la máquina. El origen de los cortocircuitos, generalmente, se debe a la degradación intrínseca de los compuestos orgánicos que forman el aislante. Esta degradación se puede ver acelerada por factores térmicos y por su influencia con las condiciones ambientales, humedad, y casos de salpicadura de aceite de los rodamientos entre otros. Ante estas circunstancias aparecen descargas eléctricas que deterioran y perforan el aislante provocando el fallo de esta parte de la máquina [31]. Hoy en día, se trabaja concienzudamente para evitar reducir este tipo de fallos haciendo a su vez máquinas más compactas (Fig. 2.5).



Figura 2.5: Estátor de un MI.

2.1.2. Fallos de excentricidad.

Los fallos de excentricidad se producen por una variación no uniforme del entrehierro existente entre el estátor y el rotor [32]. Se trata de un fenómeno muy frecuente en máquinas eléctricas de inducción. Es frecuente que las excentricidades se den como consecuencia de otros tipos de defectos, como fallos de los rodamientos o desalineamientos. El caso más crítico de este tipo de fallo es cuando se produce el colapso de la máquina, a causa del rozamiento entre el estátor y el rotor (Fig. 2.6).

Existen varios tipos de excentricidad (Fig. 2.7) [29]. La excentricidad estática se caracteriza



Figura 2.6: Consecuencias críticas de los fallos de excentricidad: contacto del rotor con el estator [5].

porque la posición donde se produce el mínimo entrehierro se mantiene fija en el espacio. Ésta puede ser originada en el proceso de fabricación por varias razones: estator con deformación geométrica en forma de óvalo, incorrecto posicionamiento del rotor, incorrecta fijación o el deterioro de los rodamientos, deformación de los soportes en las tapas, tolerancias excesivas, etc. El caso de la excentricidad dinámica se da cuando el rotor tiene imperfecciones geométricas o bien el eje de rotación no coincide con su eje geométrico. Como combinación de los problemas anteriores aparece la excentricidad mixta. Lo que sucede en este caso es que el eje de rotación no coincide con los ejes geométricos del estator y del rotor. En la práctica, es muy extraño que los casos de excentricidad estática y dinámica se den de forma aislada. Por último, la excentricidad axial acontece cuando el eje longitudinal del rotor pierde el paralelismo con el eje axial del estator.

Estos fenómenos se pueden llegar a observar en el espectro de la corriente del estator. Esto es así porque se originan unas componentes armónicas en la señal causadas por el propio giro del rotor en tales condiciones. Varios autores han deducido teóricamente las frecuencias características del fenómeno de excentricidad mixta [33]. Según la expresión (2.1) se puede observar que se encuentran distanciadas de la componente fundamental f , una distancia relacionada con la frecuencia de rotación mecánica de la máquina f_r .

$$f_{exc_{mixta}} = f + kf_r, \quad k = \pm 1, \pm 2, \pm 3, \dots \quad (2.1)$$

2.1.3. Fallos en los Rodamientos.

El rotor de una máquina eléctrica rotativa ha de estar adecuadamente posicionado dentro del estator por medio de los rodamientos los cuales absorben, en cierta medida, la fuerza magnética que aparece entre el estator y rotor. No obstante, estos elementos están sometidos a continua fricción y desgaste, aparte de agentes externos, que aceleran su envejecimiento [34,35]. Además, los rodamientos están sometidos a cargas térmicas y eléctricas que empeoran

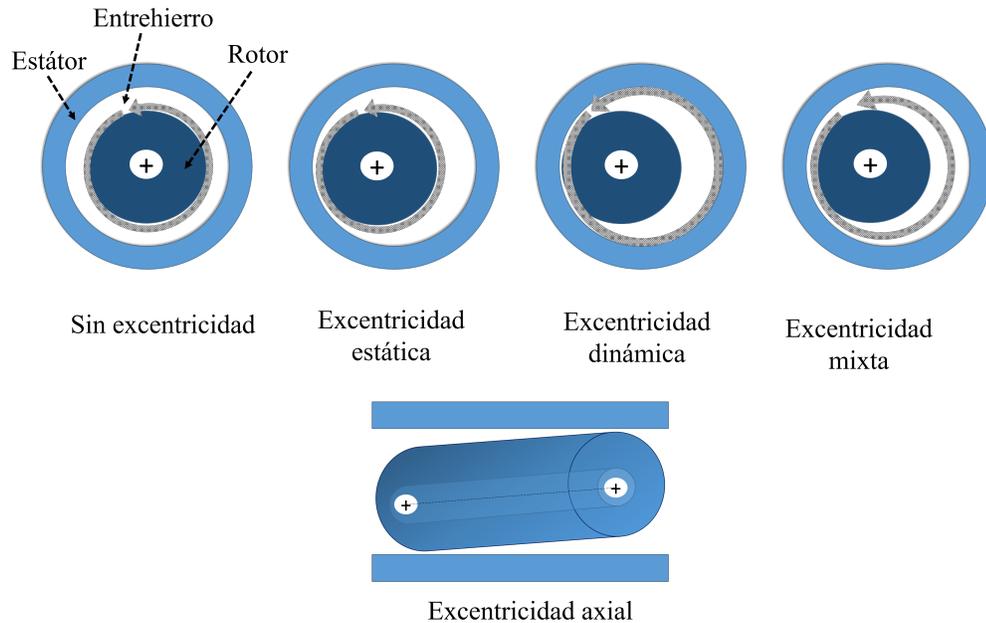


Figura 2.7: Tipos de excentricidad en un MI.

sus condiciones de trabajo. Los rodamientos usados en máquinas de no muy elevada potencia están constituidos por dos anillos, uno interno y otro externo, entre los que se disponen de manera equidistante una serie de bolas o rodillos que giran sobre dos pistas mecanizadas al efecto en dichos anillos (Fig. 2.8). Para asegurar un correcto funcionamiento dentro de su vida útil, deben mantener su estado de lubricación, ya sea por medio de grasa o de aceite dependiendo del tamaño del motor. Por lo general, los fallos en los rodamientos se detectan de manera directa o indirecta mediante análisis de vibraciones. Esto es debido a la naturaleza mecánica del fallo que hace que desde un punto de vista electromagnético su repercusión en la señal de corriente del estátor sea mínima. Un fallo de esta índole puede acontecer en alguno de los elementos que lo componen: pista exterior, pista interior y/o en sus elementos rodantes (Fig. 2.8).

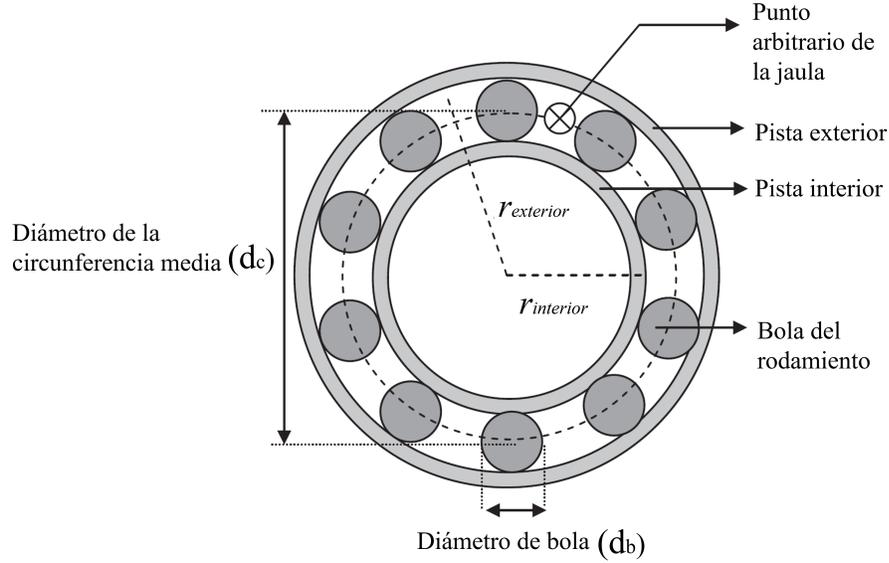


Figura 2.8: Componentes de un rodamiento.

El patrón de vibración se localizará a ciertas frecuencias dependiendo del elemento del rodamiento dañado. Para el caso de fallos localizados en la superficie de los elementos rodantes, la frecuencia de fallo viene determinada por:

$$f_{bolas} = \frac{d_c}{2d_b} f_r \left(1 - \left(\frac{d_b}{d_c} \cos \alpha \right)^2 \right), \quad (2.2)$$

donde d_c es el diámetro de la circunferencia media, d_b es el diámetro de los elementos rodantes, α es el ángulo de contacto entre los elementos rodantes y las pistas y, f_r es la frecuencia de rotación.

En cambio, las vibraciones relacionadas con los defectos en las pistas dependerán de cuantas veces pasen los elementos rodantes sobre éstas. El número de elementos rodantes que componen el rodamiento es N_b , y las frecuencias asociadas a los fallos en las pistas se expresan:

$$f_{exterior} = \frac{N_b}{2} f_r \left(1 - \frac{d_b}{d_c} \cos \alpha \right), \quad (2.3)$$

$$f_{interior} = \frac{N_b}{2} f_r \left(1 + \frac{d_b}{d_c} \cos \alpha \right). \quad (2.4)$$

Por otro lado, si el fallo sucede en la envolvente:

$$f_{envolvente} = \frac{1}{2}f_r \left(1 - \frac{d_b}{d_c} \cos \alpha \right). \quad (2.5)$$

Finalmente, resulta interesante comentar que es posible establecer una relación entre estas vibraciones y las corrientes estatóricas de la máquina, como se puede ver en [36]. Además los autores en [37] han simplificado las ecuaciones (2.3) y (2.4) para rodamientos de entre seis y doce bolas:

$$f_{exterior} = 0.4N_b f_r, \quad N_b = 6, 7, \dots, 12. \quad (2.6)$$

$$f_{interior} = 0.6N_b f_r, \quad N_b = 6, 7, \dots, 12. \quad (2.7)$$

2.1.4. Fallos en el rotor.

Por el rotor de un MI circula una corriente inducida que se distribuye por la jaula y que circula preferentemente a través de las barras o conductores que unen los dos anillos de cortocircuito [10]. Desde un punto de vista eléctrico, la asimetría rotórica es provocada por la diferente resistencia de algún elemento que conforma el circuito secundario del rotor. Dependiendo de la potencia de la máquina y, por tanto, del proceso fabricación pueden aparecer defectos internos o tolerancias de fabricación que dan lugar a asimetrías en su origen, pero de menor importancia que las de fallo. El defecto de rotura de barra, es más frecuente en máquinas de elevado tamaño, debido a los arranques y paradas continuos que sufren [5]. Esto es debido a que, las barras rotóricas soportan las fuerzas de aceleración y frenado del motor, muy frecuentes en cambios de régimen, originadas por su ciclo de trabajo o por el tipo de máquina accionada, favoreciendo el desarrollo prematuro de un fallo ocasionado por la fatiga mecánica del material [38]. Por lo general, los rtores de motores de pequeño y mediano tamaño se fabrican con fundición de aluminio o cobre obteniéndose simultáneamente las barras y los anillos de cortocircuito. Para motores de potencias por encima de los 3 MW, la jaula se monta mediante la unión soldada de las barras insertadas en las ranuras y los anillos de cortocircuito de ambos extremos. Los problemas pueden iniciarse por una mala soldadura de estos elementos ya que las uniones soldadas acumulan las mayores tensiones mecánicas de la estructura rotórica. Por otro lado, en motores construidos por fundición se pueden crear porosidades que dan lugar a puntos calientes. Ambas situaciones dan lugar a un deterioro gradual provocado por estrés de origen térmico, mecánico y electromagnético durante la

operación del motor. La presencia de gradientes térmicos y de un importante estrés termomecánico en el rotor [38] daña principalmente la unión de la barra con el anillo de cortocircuito (Fig. 2.9), impidiendo la circulación de corriente dando lugar a corrientes interlaminares [35] y originando una importante asimetría en la distribución del campo magnético alrededor del rotor.

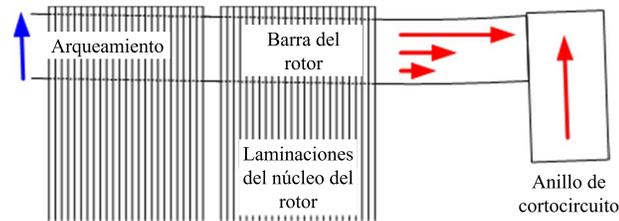


Figura 2.9: Desarrollo típico de una grieta en la jaula producida en la unión barra-anillo con crecimiento axial y radial [5].

Los gradientes térmicos causados suelen conducir a una dilatación diferencial que torsiona y agrieta los anillos. Una vez que esto sucede, el proceso se retroalimenta: la barra defectuosa sufre un calentamiento en la zona de la fisura, donde las tensiones se incrementan hasta la rotura. Posteriormente, aparecen arcos eléctricos entre las dos partes separadas, que dañan el circuito. El fenómeno se propaga hacia las barras adyacentes las cuales soportan mayores corrientes empeorando el estado del rotor (Fig. 2.10).



Figura 2.10: Grietas y separación de la unión barra-anillo en un rotor de cobre soldado [5].

Las consecuencias más inmediatas de este fenómeno son:

- Aflojamiento de las barras provocado por la separación y grietas originadas en la unión barra-anillo de cortocircuito en motores de cobre soldado.
- Porosidades, grietas y la fusión en la barra o anillo en motores de fundición de aluminio.
- Aumento del estrés producido por la distribución de la corriente en barras adyacentes.

- La corriente entre barras provoca arcos intermitentes entre el núcleo del rotor y la barra afectada, deteriorando el núcleo del rotor.
- Aumento en la vibración, del par, o pulsaciones de velocidad y ruidos.
- Aumento de la temperatura y pérdidas locales.

Sin embargo, pueden producirse otros daños derivados de los anteriores como la interrupción forzada del motor debida a la protrusión de la barra del rotor (Fig. 2.11) o del fragmento de la barra y, riesgos de seguridad y daños en el núcleo provocados por los arcos eléctricos. Usualmente, el periodo que transcurre desde que falla una barra hasta que la máquina padece al fallo catastrófico es amplio. El mecanismo de fallo de barra rota es especialmente viable a ser tratado con políticas de mantenimiento predictivo, y es por ello que su detección temprana es una oportunidad de investigación en el área del diagnóstico automático. El elevado coste y la importancia de los sistemas donde operan los equipos propensos a sufrirla respalda las investigaciones destinadas a identificar este tipo de fallo, a pesar de su menor tasa de aparición.



Figura 2.11: Protrusión en la jaula del rotor en un motor de 6 kV, 1400 kW primarios (motor de un ventilador) [39].

Como se verá a continuación, el análisis de la corriente de alimentación del estator ha sido el método más extendido para la detección de la rotura de barras y anillos de cortocircuito en las máquinas de inducción. Esto es así porque en la señal de la corriente se manifiestan las componentes armónicas características de este tipo de fallo, cuyas frecuencias han sido

determinadas de manera teórica [10, 23, 40]:

$$f_{asim,rotor} = \left(\frac{k}{p}(1-s) \pm s \right) f, \quad \frac{k}{p} = 1, 3, 5, \dots \quad (2.8)$$

donde k es el número de orden de armónico, p el número de pares de polos, s el deslizamiento y f la frecuencia de alimentación. La adición de s indica que los armónicos son generados por el campo que gira en el mismo sentido que el rotor, mientras que la sustracción hace referencia a los que giran en sentido contrario. No obstante, debido al carácter discreto del devanado por razones constructivas, la simetría del campo y el factor de devanado causan que no todos los armónicos sean capaces de afectar a la corriente del estator. Además, en la práctica, no sólo aparecen los armónicos laterales expresados en (2.8), sino que éstos a su vez generan fluctuaciones en el par entregado o producido (si la máquina funciona como generador), provocando oscilaciones que dan lugar a pulsaciones en la velocidad de la máquina induciendo de este modo, otros armónicos en la corriente estatórica [41]. Por ejemplo, en el caso de $k = p = 1$ en (2.9) y (2.10) se obtienen el armónico lateral izquierdo (LSH) y el armónico lateral derecho (RSH) de la componente fundamental respectivamente:

$$f_{LSH} = (1 - 2s)f, \quad (2.9)$$

$$f_{RSH} = (1 + 2s)f. \quad (2.10)$$

La componente LSH origina una pulsación en el par y, por tanto, una modulación en la velocidad de la máquina (ya que no se puede asumir una inercia infinita del grupo máquina-carga) que a su vez modula el flujo magnético a frecuencia $2sf$. En consecuencia, se generan dos componentes armónicas en la corriente estatórica de la máquina de frecuencias correspondientes a las ecuaciones (2.9) y (2.10). Estas componentes han sido muy empleadas en el diagnóstico de máquinas eléctricas [17, 42, 43]. Este efecto de modulación se reproduce en cascada. De este modo, el armónico RSH a su vez genera en el rotor una componente $3sf$, lo que genera nuevos pares de bandas armónicas alrededor de la frecuencia fundamental de la alimentación del estator [44]. De manera repetida, van apareciendo bandas de frecuencias alrededor de la componente fundamental, separadas entre sí una distancia de $2sf$ (Fig. 2.12). Estas componentes de frecuencia se pueden obtener con la siguiente expresión:

$$f_{asim,rotor} = (1 + 2ks)f, \quad k = \pm 1, \pm 2, \pm 3, \dots \quad (2.11)$$

Nótese que, cuando ocurren otros fenómenos del tipo saturación magnética [23], corrientes interlaminares u otras asimetrías magnéticas originadas por la carga [5] estas componentes pueden dar lugar a falsas indicaciones.

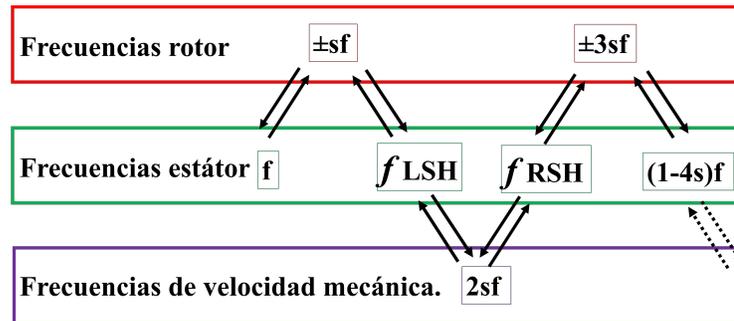


Figura 2.12: Frecuencia de propagación de un fallo de barra rota [44].

2.2. Magnitudes empleadas para la detección de anomalías en el motor.

2.2.1. Técnicas basadas en modelos del motor.

La identificación de fallos por medio de técnicas basadas en modelos suele emplearse en el diagnóstico de máquinas rotatorias, cuando la tarea principal es localizar y evaluar la gravedad de un mal funcionamiento. Sin embargo, la máquina totalmente montada está compuesta por submodelos (cojinetes y cimentación), donde a menudo no se es capaz de reproducir correctamente la influencia del comportamiento dinámico de la estructura de soporte sobre el eje, especialmente en máquinas grandes donde están presentes modos acoplados [45]. En [46] se realiza el estudio para variaciones de las condiciones de funcionamiento, ambiente, carga, ciclos de trabajo, etc. Además, existen técnicas basadas en los modelos circuitales del motor. Para la medida de las impedancias se emplea la teoría de componentes simétricas, donde cualquier sistema trifásico desequilibrado puede descomponerse en dos sistemas equilibrados de secuencia directa e inversa y en un conjunto de fasores de igual fase denominado componentes homopolares [47]. Por tanto, se puede calcular la impedancia de cada secuencia por medio de la ley de Ohm. De esta manera, es posible detectar fallos en máquinas eléctricas a través de la variación de impedancias. No obstante, su validez se ha demostrado únicamente para pequeños desequilibrios.

2.2.2. Análisis de vibraciones.

Generalmente, el análisis de vibraciones se usa para la detección de fallos mecánicos como fallos en rodamientos, engranajes de acoplamiento, o el mismo desalineamiento del rotor. Además, pueden producirse vibraciones de la carcasa como consecuencia de cortocircuitos en

el bobinado del estátor, desbalance en el suministro o barras rotas [2]. La señal de vibración se captura con transductores colocados en los rodamientos para medir en las direcciones radial y/o axial. El problema general que tiene la detección basada en vibración es el acoplamiento mecánico entre el componente que se supervisa, por ejemplo, un rodamiento y otros componentes estructurales adyacentes, por ejemplo, un eje o motor. Dicho acoplamiento introduce una interferencia en la señal de vibración asociada únicamente con el componente de interés, dando como resultado una mala calidad de los datos. Para mejorar la calidad de los datos de detección, es necesario mejorar las características del sensor para que se adapte mejor a la señal de interés u optimizar su colocación [48]. Sin embargo, este tipo de señal se ha empleado en trabajos como [49] donde se analizan técnicas tiempo-frecuencia del espectro de la señal de vibración para abordar el problema de fallos en rodamientos debido a corrientes que circulan por los mismos a causa del uso de convertidores de frecuencia. Por otro lado, también con señales de vibración tratan el problema de barras rotas en [50] realizando un diagnóstico basado en clustering y su implementación en FPGA. Los autores consiguen desarrollar un sistema automático de fallos cuantificando la severidad de fallo por medio del teorema de entropía de Shannon. En [51] se muestra un estudio comparativo de técnicas tiempo-frecuencia donde se emplean señales de vibración obtenidas durante el transitorio de arranque para diagnosticar fallos de barras rotas, rodamientos y desequilibrios en el eje. Este método resultó eficaz para aquellos casos donde se alimenta al motor con inversores que introducen alto contenido en ruido en la señal de corriente.

2.2.3. Análisis del flujo magnético.

Otra magnitud empleada para detectar fallos es el flujo de dispersión [40, 52, 53]. Éste se produce en una máquina de inducción con rotor en jaula de ardilla como resultado de las corrientes del estátor y rotor en los extremos de la máquina, es decir, en los extremos de los finales de las bobinas del estátor y en los anillos de cortocircuito del rotor. A causa de la inherente asimetría debida al proceso de manufactura, el flujo de dispersión puede ser detectado siempre aún en condiciones de suministro simétrico de potencia. Cuando se produce un fallo en el estátor o en el rotor, la distribución de los armónicos espaciales en el entrehierro se modifica. Estos armónicos, además de reflejarse en la corriente del estátor, se reflejan en el flujo de dispersión. Si la máquina opera en régimen estacionario los cambios en el flujo pueden llegar a reflejar los armónicos de barras rotas. Esta medida es más sensible a detectar fallos cuando se emplea una bobina de búsqueda alrededor de la máquina [40]. Autores como Frosini *et al.* [53] desarrollaron una técnica basada en la medida del flujo axial

en diferentes posiciones de la máquina. Entre las principales ventajas destacan la simplicidad y flexibilidad de customizar la sonda de medida del flujo, la cual requiere de una etapa previa de filtrado. La sonda de flujo puede posicionarse fácilmente en las máquinas y adaptarse a una amplia gama de niveles de potencia. Aunque esta magnitud ha demostrado ser válida para la detección de fallos [63] de manera teórica, su uso práctico está limitado por las dificultades que entraña su medida [34] y por su incapacidad para cuantificar el fallo.

2.2.4. Medida del par.

En una máquina de inducción real el par ofrecido por la misma es oscilante como consecuencia de la distribución del devanado repercutiendo en la velocidad con la que gira el eje. De forma teórica, las frecuencias de oscilación de un motor sano pueden ser calculadas [9]. Tomando como referencia estas frecuencias teóricas del motor sano, se puede plantear una comparativa del par ofrecido por la máquina bajo el patrón de la máquina sana, y observando las desviaciones de éste si acontece algún tipo de fallo. En la práctica, los sensores de medición de par mecánico tienen un coste económico muy elevado, además de tener que ser instalados en el eje, siendo inaccesible en muchas aplicaciones industriales. Una alternativa a ello es calcular el par electromagnético de la máquina. El par electromagnético se puede determinar a partir de las medidas de corriente y tensión. Además, se utilizan sensores cuyo uso está ampliamente extendido en la industria con un coste relativamente bajo. Para fines de diagnóstico, el par electromagnético de una máquina eléctrica [54] se puede calcular como:

$$T = \frac{p}{2\sqrt{3}}(i_a + i_b) \int_0^T (v_{ca} - R(i_c - i_a))dt - \frac{p}{2\sqrt{3}}(i_c + i_a) \int_0^T (v_{ba} - R(i_a - i_b))dt, \quad (2.12)$$

donde i_a , i_b e i_c son las corrientes instantáneas de fase estatóricas, v_{ba} y v_{ca} son las tensiones instantáneas entre fases, R es la resistencia del devanado estatórico y, p el número de pares de polos. La ecuación (2.12) se puede expresar en un sistema bifásico si se utiliza la teoría de los fasores espaciales ($d - q$). Para ello, aplicando la transformada de Park, el par interno o electromagnético se puede calcular según [54]:

$$T = \frac{3}{2}p(\Psi_d i_q - \Psi_q i_d), \quad (2.13)$$

donde i_d e i_q son las proyecciones del vector de corrientes sobre los ejes d y q respectivamente; Ψ_d e Ψ_q son los enlaces de flujo totales según los ejes d y q .

2.2.5. Potencia instantánea.

La potencia instantánea $P(t)$ ha sido una magnitud bastante utilizada en el campo del diagnóstico de máquinas eléctricas. Ésta se puede obtener de la medida de tensiones y corrientes de la máquina y puede ser expresada en dos términos como [55]:

$$P(t) = P_{AB}(t) + P_{CB}(t), \quad (2.14)$$

$$P_{AB}(t) = V_{LL}I_L \left(\cos \left(\varphi + \frac{\pi}{6} \right) + \cos \left(2\omega t - \varphi + \frac{\pi}{6} \right) \right), \quad (2.15)$$

$$P_{CB}(t) = V_{LL}I_L \left(\cos \left(\varphi - \frac{\pi}{6} \right) + \cos \left(2\omega t - \varphi + \frac{\pi}{6} \right) \right), \quad (2.16)$$

donde $P(t)$ es la potencia instantánea total de entrada; P_{AB} y P_{BC} son los valores de potencia instantánea de entrada parciales; V_{LL} e i_L son los valores eficaces de la tensión de línea y la corriente de línea respectivamente; ω es la frecuencia de alimentación en radianes por segundo y φ es el ángulo del factor de potencia. No obstante, existen otras técnicas para obtener el valor de la potencia instantánea como, por ejemplo, el sumatorio del producto de la tensión y la corriente, para lo que se miden las tres tensiones y las tres corrientes de fase [56], o el producto de la tensión entre dos fases por la corriente de fase [42, 57], entre otros. Los autores de [30] han analizado las firmas de fallo obtenidas de las potencias instantáneas activa y reactiva para detectar fallos en el estátor de un MI de jaula de ardilla alimentado tanto de red como por inversor obteniendo resultados prometedores. La principal ventaja que tiene el estudio de las potencias instantáneas es que en él aparecen componentes armónicas de la combinación de la onda de la tensión y de la corriente lo que permite reducir el efecto de fuga espectral del espectro de corriente provocado por la componente de energía fundamental [56, 57]. A pesar de las ventajas que tiene esta técnica, algunos autores sostienen que se pierde mucha información para cuantificar adecuadamente el fallo [44]. Otro inconveniente de esta técnica, es que se requieren dos sensores para la captura de las señales [2].

2.2.6. Tensiones residuales a la desconexión.

Esta magnitud consiste en obtener información de las tensiones residuales que aparecen en el estátor una vez desconectada la máquina de su alimentación. Esto es debido a que por el rotor siguen circulando corrientes durante unos instantes, creando un campo magnético

giratorio y, por tanto, induciendo tensiones en el estátor. En caso de fallo, aparecen componentes armónicas anormales que indican la situación de fallo [58, 59]. Para su cálculo se pueden consultar los siguientes trabajos [58, 59].

2.2.7. Emisiones acústicas y sonido.

Las emisiones acústicas y el sonido son fenómenos físicos que proporcionan información sobre el comportamiento de un sistema y pueden utilizarse como magnitudes para determinar la condición de un MI [60, 61]. Las emisiones acústicas se producen como consecuencia de la liberación de energía de deformación causada por una alteración estructural en un material sólido bajo estrés. Por otro lado, algunas de las posibles causas del ruido en un MI, son [62]: armónicos de ranura, armónicos de suministro, desequilibrio de rotor, asimetría de bobinado y los cojinetes. Algunos de ellos son inherentes al diseño de la máquina y por lo tanto aparecen de forma permanente durante su vida útil (armónicos de ranura, asimetría de bobinado). Pero otros se desarrollan con el tiempo, y pueden conducir en última instancia al fallo de la máquina (cojinete, desequilibrio, barras rotas del rotor). Otros se deben a circunstancias externas, como los armónicos introducidos por la fuente de alimentación. Todos estos se suman al sonido emitido por el motor, lo que dificulta el análisis por medio de esta señal.

2.2.8. Análisis por termografía.

Técnicas como la termografía infrarroja han sido recientemente estudiadas como técnicas de mantenimiento predictivo de máquinas rotatorias [63, 64]. Si bien es cierto que, este tipo de técnicas por sí solas no tienen el potencial de aquellas basadas en el análisis de la corriente estatística o el análisis de vibraciones. Sin embargo, pueden ser usadas como complemento al diagnóstico de desalineamientos, problemas de refrigeración, cojinetes o defectos en las conexiones [63]. Claro está que no existe una técnica exclusiva capaz de detectar todos los tipos de fallos que puedan ocurrir en una máquina rotativa [65]. En [65] proponen una doble estrategia para detectar fallos electromecánicos en los MI. Ellos emplean un método que analiza las corrientes tanto en transitorio como en estado estable combinado con el análisis a través de termografía infrarroja. Lo más interesante de su trabajo es que permite detectar anomalías en el sistema de refrigeración, fallos en el rotor, así como en los cojinetes a través de un procedimiento no invasivo.

2.2.9. Análisis de la corriente estatórica.

De la amplia literatura científica que trata el diagnóstico de los MI se evidencia que tanto las vibraciones como la corriente estatórica son las magnitudes más utilizadas. Con el análisis de la corriente estatórica, se pueden identificar de manera simultánea defectos del tipo de excentricidad mixta, fallos en alguna de las partes de los rodamientos y fallos de rotura de barras [66] en un MI. Por lo general, MCSA es un método más sensible para la detección de barras rotas, mientras que el análisis de vibraciones es más efectivo para detectar fallos en los rodamientos y averías estrictamente mecánicas. Además, para el análisis de la corriente estatórica existen un elevado número de sensores de uso muy extendido en el ámbito industrial con un reducido coste, que permiten realizar una medida no invasiva, independiente del entorno donde opera la máquina, de forma remota y sobretodo, sin alterar el funcionamiento de la máquina. Además de estas ventajas, la rápida expansión de técnicas basadas en el análisis espectral de dicha magnitud, cuyas frecuencias características dependen de cada tipo de fallo, la ha situado como una de las mejores magnitudes a monitorizar. Para la captura de la señal de corriente, es necesario convertir la onda de corriente a una señal proporcional de tensión que conserve la misma información espectral que ésta. Los sensores o equipos más utilizados para este fin han sido: resistencias calibradas tipo shunt, transformadores de intensidad y sondas de efecto Hall [34].

Dadas las características tanto de calidad para el diagnóstico como de implementación que presenta el análisis de la corriente estatórica para el estudio del fallo de barra rota de un MI, en esta tesis doctoral se ha diseñado un banco de ensayos para la monitorización de la misma.

2.3. Técnicas de detección.

La señal de la corriente obtenida directamente del sensor no ofrece ninguna información útil para la detección de fallos, pues con la mera observación de la señal en el osciloscopio no se logra diferenciar ningún síntoma de avería. Con el objetivo de usar esta señal en el diagnóstico de fallos, primero debe ser procesada para poder extraer de ella ciertas características o variables indicativas de fallo. Por ello, a continuación, se hace un repaso de la literatura sobre las técnicas de detección de fallo basadas en el análisis de la corriente estatórica ya que, la corriente estatórica es la magnitud empleada en esta tesis doctoral para la extracción de patrones del motor. Primeramente, se tratan las técnicas aplicadas en régimen estacionario y que sirven para extraer indicadores de fallo de un motor. Finalmente se exponen brevemente

algunas de las técnicas que han sido recientemente aplicadas en el régimen transitorio.

2.3.1. Detección en régimen estacionario.

Las primeras técnicas de detección en régimen estacionario fueron desarrolladas para motores alimentados directamente de la red eléctrica [10]. Posteriormente, se desarrollaron técnicas de análisis espectral para el reconocimiento de patrones de fallo que aparecen en la señal de corriente del estátor. La transformada rápida de Fourier o *Fast Fourier Transform* (FFT) como es conocida en inglés, tomó un papel fundamental para la obtención de patrones de fallo en el dominio de la frecuencia sobre el que se han basado muchas herramientas de diagnóstico [67, 68]. Su empleo resultó satisfactorio para detectar fallos en el rotor de motores alimentados de red en régimen estacionario. En el análisis espectral de la FFT se analiza el contenido de armónicos de la corriente para identificar cuáles son las componentes propias de un motor en estado sano, y cuáles son las componentes vinculadas a averías. Bien es cierto que varios trabajos han propuesto índices que relacionan la amplitud de las componentes armónicas con el grado de severidad del fallo [44, 69]. Sin embargo, cuando el motor está alimentado por un convertidor de frecuencia y para fallos incipientes, resulta complicado la extracción de dichas amplitudes usando únicamente la FFT. Los autores en [69] propusieron unos índices que permiten obtener información del estado de la máquina para las señales del estátor con alto contenido armónico, como en el caso de un motor alimentado por inversor. A continuación, se describen brevemente las técnicas más usadas en la literatura para detección en estado estacionario que servirán como antecedente a las técnicas desarrolladas en esta tesis.

2.3.1.1. Vector extendido de Park.

El vector extendido de Park es una técnica que tiene como objetivo eliminar la componente fundamental y evitar el efecto de fuga. Este método realiza un análisis espectral de la componente alterna del módulo del vector de Park [34]. La transformada de Park es ampliamente conocida y consiste en convertir el sistema de referencia trifásico de la máquina (R-S-T) variable en el tiempo en un sistema bifásico (D-Q-0) que gira en el espacio. Las componentes de dicho vector (i_D y i_Q) se pueden calcular a partir de las corrientes de las tres fases de la máquina (i_R , i_S y i_T) [70]. En el caso de motor sano, la trayectoria descrita por las componentes describiría una circunferencia circular. Cuando aparece algún tipo de anomalía, la amplitud del módulo varía, a diferencia del caso donde la máquina está sana. Por lo tanto, el vector extendido de Park trata de estudiar las frecuencias que provocan dicha

modulación en la amplitud del vector. La principal ventaja de este método es que no elimina las frecuencias negativas lo que permite detectar las componentes que giran en sentido opuesto a la componente fundamental. Es decir, permite detectar los órdenes de armónico de fallo tanto positivos como negativos.

2.3.1.2. Mapas de colores.

Esta técnica se basa en la creación de patrones gráficos, como los mapas de ADN usados en disciplinas como la genética para, de una forma visual y sencilla, verificar el estado de la máquina eléctrica [71]. Aunque, matemáticamente hablando esta técnica no es muy rigurosa, a través del conocimiento de las frecuencias características de fallo antes introducidas, se pueden crear diccionarios de patrones. Esta técnica fue diseñada como una metodología de extracción de patrones para realizar diagnósticos inteligentes de fallos en máquinas de inducción. Sin embargo, esta técnica no parece muy atractiva para ser usada por algoritmos de aprendizaje automático y sí más bien directamente por personal de mantenimiento.

2.3.1.3. Técnicas en el dominio del tiempo.

El análisis en el dominio del tiempo existe desde la aparición del osciloscopio, y permite analizar las características básicas de las formas de onda [2, 35]. Muchos autores han usado las características estadísticas obtenidas directamente de la señal en el dominio del tiempo, tanto de vibración [22, 72, 73] como de corriente [74]. Algunos de los parámetros estadísticos de orden superior, conocidos también como Higher Order Statistics (HOS) [75], tienen la propiedad de ser sensibles a mediciones distribuidas de forma diferente a la gaussiana. Sin embargo, las estadísticas de orden inferior, aquellas que utilizan desde términos constantes a cuadráticos (por ejemplo, primer y segundo momento) son significativamente más robustas. En el capítulo 3, se explican los estadísticos empleados como variables para la herramienta de diagnóstico automático desarrollada en la presente tesis.

2.3.1.4. La Transformada Rápida de Fourier (FFT).

Una de las técnicas más utilizadas para analizar las frecuencias presentes en una señal estacionaria es la transformada de Fourier. Jean Baptiste-Joseph Fourier estableció por medio de las series que llevan su apellido, que cualquier onda periódica X_p , puede ser descompuesta

como una suma infinita de ondas sinusoidales de diferente frecuencia f y amplitudes a_k y b_k .

$$X_p(t) = \frac{a_0}{2} + \sum_{k=1}^{+\infty} [(a_k) \cos(2\pi kft) + (b_k) \sin(2\pi kft)]. \quad (2.17)$$

Por ende, con la transformada de Fourier (2.18) se puede obtener el espectro de frecuencias característico de la señal.

$$X(f) = \int_{-\infty}^{+\infty} x(t)e^{-j2\pi ft} dt. \quad (2.18)$$

Esto es así ya que, la integral solo se anulará para aquellas frecuencias de las sinusoidales diferentes a $e^{-j2\pi ft}$ que no correspondan a alguna componente de la señal original ($x(t)$). En la realidad, se requiere llevar a cabo la Transformada Discreta de Fourier (DFT) ya que las señales muestreadas están formadas por puntos discretos de una señal. Además, para lograr un eficiente cómputo de la DFT en el campo del diagnóstico, en la práctica se hace uso de la FFT [76]. La primera vez que fue utilizada esta técnica para diagnósticos de motores fue en la década de los años 80 [10]. Este hito convirtió a la corriente estatórica como la magnitud por excelencia para el diagnóstico de máquinas eléctricas rotativas, siendo válida para un gran número de aplicaciones que trabajen en régimen estacionario. Sin embargo, tiene fuertes limitaciones que restringen su uso como única herramienta para el diagnóstico, entre los que cabe citar [1, 77, 78]:

- Sólo es válida para señales estacionarias.
- La FFT es muy sensible ante señales con un bajo ratio señal-ruido. La señal de la corriente del estátor tiene un alto contenido en ruido por varias razones: interferencia electromagnética por su operación con máquinas de los alrededores, disturbios en la señal de suministro de potencia causados por cargas no lineales y/o transitorios provocados al conectar cargas; y los indeseables interarmónicos introducidos por los inversores que alimentan al motor.
- Sufre el fenómeno de fuga espectral provocado por la componente de energía fundamental la cual es muy superior a los armónicos de fallo. Este aspecto es crítico para aquellos casos donde el motor opera a bajos deslizamientos [17, 79], ya que cuanto más próximas estén las componentes de fallo a la fundamental mayor será la influencia de este fenómeno llegando a ocultar las componentes de fallo [78]. En [80] se investiga el uso de ventanas bajo la presencia de una fuerte interferencia armónica. Particularmen-

te, en [81] se ha hecho frente a esta problemática tratando de minimizar sus efectos mediante el uso de la ventana Hanning.

- La resolución en frecuencia es otro inconveniente de la FFT, ya que para obtener una adecuada resolución en frecuencia se requieren periodos relativamente largos de la señal en estado estacionario, lo cual es complicado en la práctica por las pequeñas oscilaciones siempre presentes en la carga.
- Fenómeno de aliasing. Según el teorema del muestreo de Nyquist-Shannon [82] el límite teórico de frecuencias que se pueden estudiar es la mitad de la frecuencia de muestreo. Para frecuencias de muestreo fuera de este criterio se produce un alias en frecuencia y por tanto, se obtienen resultados erróneos de la señal de interés. Para aminorar este efecto, en la práctica es habitual usar filtros analógicos anti-aliasing o muestrear con una frecuencia de muestreo de cinco a diez veces superior a la máxima frecuencia a observar en la señal medida.

Como ejemplo, en [78] se propone una técnica de procesamiento de señales a razón múltiple que mejoran los métodos basados en la FFT para detectar fallos de barra rota en MI, minimizando el efecto de fuga espectral.

2.3.1.5. Análisis de la señal analítica.

El análisis de la señal analítica se puede realizar con la transformada integral de Hilbert (HT). Esta técnica permite mitigar el efecto de fuga espectral y por tanto ser utilizada en la detección de fallos en MI ante condiciones de bajo deslizamiento [1,83,84]. La señal analítica ($\vec{x}(t)$) es una señal compleja cuya parte real es la señal original ($x(t)$) y la imaginaria es la HT (2.22) de la señal original ($HT(x(t))$) [85] (Fig. 2.13).

$$\vec{x} = x(t) + jHT(x(t)) = x(t) + jy(t), \quad (2.19)$$

expresado también como:

$$\vec{x} = a(t)e^{j\theta(t)}, \quad (2.20)$$

donde $a(t)$ es la amplitud instantánea de la señal analítica que determina la variación de la energía de $x(t)$ con el tiempo y $\theta(t)$ es la fase de $\vec{x}(t)$ que se define como:

$$\theta(t) = \arctan \frac{x(t)}{y(t)}. \quad (2.21)$$

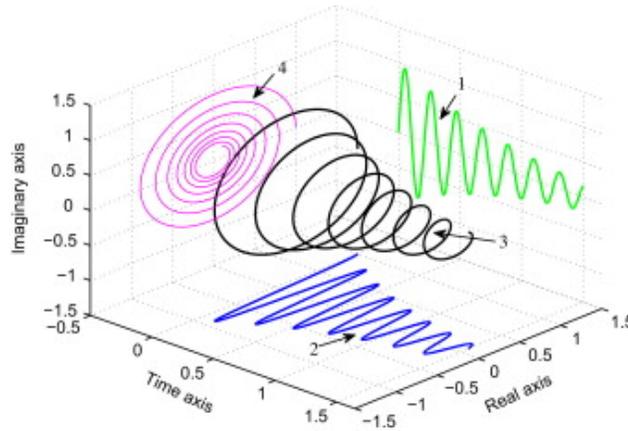


Figura 2.13: Proyección de: la HT (1), la señal real (2), la señal analítica (3), el fasor en el plano complejo (4) [85].

Debido a una posible singularidad en $t = \tau$, la integral tiene que ser considerada como un valor principal de Cauchy [85]. La HT de una función real $x(t)$ que se extiende de $-\infty$ a $+\infty$ es una función de valor real $y(t)$ definida por:

$$HT(x(t)) = y(t) = \frac{1}{\pi} \int_{-\infty}^{+\infty} \frac{x(\tau)}{\pi - t} d\tau. \quad (2.22)$$

Físicamente, la HT es equivalente a un tipo especial de filtro lineal, donde todas las amplitudes de los componentes espectrales se dejan inalteradas, pero sus fases son desplazadas por $-\frac{\pi}{2}$ [85]. Por lo tanto, la representación de la HT, $y(t)$, de la función original es la integral de convolución de $x(t)$ con $(\pi - t)^{-1}$. De este modo, el espectro resultante tiene la misma frecuencia y amplitud que la señal original pero las frecuencias están desfasadas $\frac{\pi}{2}$. Las principales características que hacen a la señal analítica apropiada para el diagnóstico de máquinas eléctricas son las siguientes:

- En el espectro de la señal analítica ($\vec{x}(t) = x(t) + jHT(x(t))$), el nivel original de frecuencias positivas se mantiene, las negativas se anulan y se duplica el contenido de la componente continua [86].
- Respecto a la señal original, las bajas frecuencias quedan contenidas en la amplitud $a(t)$ mientras que las altas frecuencias se localizan en la fase $\theta(t)$ de la señal analítica.

Es frecuente que, para detectar fallos en una máquina se emplee la componente alterna del

módulo de la señal analítica (i_{AS}) de la siguiente forma:

$$i_{AS} = \frac{|\vec{i}_r(t)| - |\vec{i}_r|}{|\vec{i}_r|}, \quad (2.23)$$

donde $|\vec{i}_r(t)|$ es el valor instantáneo del módulo de la señal analítica y $|\vec{i}_r|$ es el valor medio del módulo de la señal analítica. De esta manera, se procede a eliminar la componente fundamental al convertirse en una componente continua y, por tanto, se anula el efecto de la fuga espectral antes mencionado. El uso de la componente alterna del módulo de la señal analítica para la detección de fallos aporta las siguientes ventajas [83]:

- Aplicación relativamente sencilla ya que sólo precisa de la medida de la corriente de una de las fases del estátor.
- Las componentes negativas del espectro se anulan y sólo aparecen las componentes de fallo correspondientes a órdenes de armónico positivos.
- Como ya se ha mencionado, el efecto de la fuga espectral producido por la componente fundamental queda anulado.
- La legibilidad del espectro se mejora ya que debido a la ausencia de la componente fundamental el eje de ordenadas puede ser expresado en escala lineal.
- La banda de frecuencias a analizar se reduce ya que, la información relativa a los fallos se ubica en el rango de las bajas frecuencias, por lo que, las altas frecuencias pueden ser desechadas no siendo necesario tanto almacenamiento como con la FFT.

2.3.1.6. Transformada Multiple Signal Classification (MUSIC).

Los métodos subespaciales son conocidos como métodos de alta resolución que detectan frecuencias en señales con baja relación señal-ruido [17, 18, 87]. El algoritmo MUSIC estima el contenido de frecuencia de una señal utilizando una descomposición de vectores propios de la matriz de autocorrelación. En este método se supone que $x[n]$, la señal de corriente del estátor de tiempo discreto, es una suma de M sinusoides complejas con ruido blanco y se puede expresar como sigue:

$$x[n] = \sum_{i=1}^M \bar{A}_i e^{j2\pi f_i n} + e[n], \quad (2.24)$$

con

$$\bar{A}_i = |A_i|e^{j\phi_i}, \quad (2.25)$$

y $n = 0, 1, 2, \dots, N - 1$ donde N es el número de muestras, $|A_i|$ es la magnitud, f_i es la frecuencia, ϕ_i es la fase aleatoria de la i -ésima senoide compleja, $e[n]$ es ruido blanco de media nula y varianza σ^2 . \mathbf{R}_x es la matriz de autocorrelación de dimensiones $M \times M$ de la señal $x[n]$, la cual puede ser expresada como la suma de las matrices de autocorrelación de la señal y de su contenido en ruido \mathbf{R}_s y \mathbf{R}_n respectivamente, como sigue:

$$\mathbf{R}_x = \mathbf{R}_s + \mathbf{R}_n = \sum_{i=1}^m |A_i|^2 \mathbf{e}(f_i) \mathbf{e}^H(f_i) + \sigma^2 \mathbf{I}, \quad (2.26)$$

donde m es el número de componentes de frecuencia, el exponente H denota la transpuesta Hermitiana, \mathbf{I} es la matriz identidad, y $\mathbf{e}^H(f_i)$ es el vector de la señal dado por:

$$\mathbf{e}(f_i) = [1 \ e^{j2\pi f_i} \ e^{j4\pi f_i} \ \dots \ e^{j2\pi(N-1)f_i}]^T \quad (2.27)$$

De la condición de ortogonalidad de ambos subespacios, el pseudo-espectro de MUSIC Q está dado por:

$$Q^{MUSIC} = \frac{1}{|\mathbf{e}^H(f_i) \mathbf{v}_{m+1}|^2}, \quad (2.28)$$

$$\mathbf{v}_{m+1} = \sum_{k=m+1}^M \mathbf{v}_k \mathbf{v}_k^H, \quad (2.29)$$

donde \mathbf{v}_{m+1} es el autovector del ruido y está expresado en (2.29). Esta expresión exhibe los picos que están a frecuencias de las componentes senooidales principales, donde $\mathbf{e}(f)^H \mathbf{v}_{m+1} = 0$. El escalar entero y parámetro de ajuste m , también conocido como orden de MUSIC representa la dimensión del subespacio de ruido de la señal. Con esta técnica se pueden resolver algunos de los inconvenientes que presenta la FFT como la fuga espectral, mejorar la resolución en frecuencia, y también obtener un espectro menos afectado por el ruido, especialmente para casos de alimentación por inversor. Los autores en [87] usan una técnica de análisis de alta resolución basada en un método capaz de estimar la frecuencia con técnicas de zoom (ESPRIT y MUSIC), y la amplitud, estimando los parámetros de la señal con técnicas de invarianza rotacional (estimador por mínimos cuadrados). Esta técnica ha dado buenos resultados para fallos de una y dos barras rotas de un MI. En [17] se desarrolla una etapa de seguimiento de la componente fundamental usando un filtro Kalman extendido junto con

el algoritmo MUSIC para detectar fallos de hasta media barra rota a través de la corriente estatística de un motor directamente alimentado de la red. Sin embargo, esta técnica tiene el inconveniente de que resulta muy complejo escoger adecuadamente el parámetro m que permita discriminar entre situaciones de fallo incipiente de aquellas correspondientes al motor en estado sano. A pesar del potencial que tiene esta técnica no se han desarrollado trabajos que analicen la detección de fallos incipientes ante motores alimentados por inversor.

2.3.1.7. Análisis del orden armónico.

El análisis del orden armónico o Harmonic Order Tracking Analysis (HOTA) en inglés, es una técnica de diagnóstico apta para cualquier condición de funcionamiento de la máquina [88, 89]. La principal ventaja de esta técnica es que consigue dar siempre resultados basados en un diagrama del mismo tipo, tanto cuando se realiza el análisis en régimen estacionario como transitorio. HOTA se basa en realizar un cambio de sistema de referencia de modo que, en el análisis espectral, las componentes de falta queden siempre a la misma distancia con respecto a la componente fundamental. Este cambio de sistema de referencia está basado en representar el espectro en función del parámetro adimensional k (orden de armónico) que aparece en todas las ecuaciones de fallo. Este parámetro puede tomar una serie de valores enteros positivos y negativos. Si el espectro de la corriente defectuosa puede expresarse en términos del orden armónico k , en lugar de la frecuencia, entonces las líneas espectrales que revelan la presencia del fallo pueden ser localizadas directamente y evaluadas en este nuevo espectro, en las posiciones dadas por valores enteros del orden armónico k . Estas posiciones son las mismas independientemente del tipo de suministro, la frecuencia de suministro, la frecuencia de muestreo o la carga del motor, lo que facilita enormemente el trabajo de buscar firmas de fallo en la corriente del espectro. Además, esta técnica requiere menos recursos para almacenar y procesar los espectros [89] que las técnicas convencionales. Sin embargo, esta técnica de diagnóstico propuesto presenta algunas limitaciones:

- El deslizamiento de la máquina debe medirse con precisión. Esto hace que se requiera de un sensor externo para medir la velocidad.
- Para funcionamiento a bajo deslizamiento se necesita una técnica de resolución en frecuencia muy alta por el problema descrito anteriormente de fuga espectral.
- El problema de las cargas mecánicas oscilantes, las fluctuaciones de la tensión de alimentación o incluso los conductos axiales del rotor pueden introducir nuevos armónicos que dan lugar a falsas indicaciones en el espectro de la corriente. Este es un problema

tanto de la HOTA como de MCSA. Para abordar este problema, actualmente se están desarrollando otro tipo de técnicas que trabajan en condiciones transitorias.

2.3.2. Detección en régimen transitorio.

Existen situaciones donde la máquina opera ante variaciones en la carga, cargas que oscilan a baja frecuencia, continuos arranques y paradas, cambios en la velocidad de referencia, etc. [5]. Ante estas condiciones transitorias se necesitan técnicas eficaces para diagnosticar el estado de la máquina. En este intervalo de tiempo, la máquina pasa por varios estados de funcionamiento que resultan de interés para analizar la evolución de las componentes armónicas características del fallo [90], ya sean de excentricidad [15, 91], barra rota o fallo de rodamientos. Autores en [92] han usado técnicas como la *Complete Ensemble Empirical Mode Decomposition* (CEEMD) y la transformada MUSIC para analizar los patrones de fallo de un motor con una barra rota, excentricidad mixta, desalineamiento del eje o la combinación de ambas. En su trabajo se desarrolló una metodología capaz de detectar fallos en motores por medio de una señal que comprende un periodo de arranque y un periodo de régimen estacionario. Los autores lograron mostrar cómo, bajo estas condiciones de fallo y de régimen, las técnicas CEEMD y MUSIC son lo suficientemente sensibles para mostrar anomalías en motores alimentados por inversor. Sin embargo, las transformadas tiempo-frecuencia producen representaciones tridimensionales que son muy costosas desde el punto de vista del almacenamiento y costo computacional. Además, la identificación y evaluación de las componentes de fallo en el dominio tiempo-frecuencia requiere personal altamente cualificado o algoritmos de identificación de patrones muy sensibles a contrastes en el plano tiempo-frecuencia. Los autores en [88] introducen un método que reduce el tiempo de cómputo y la información que en condiciones similares se obtendría con una transformada tiempo-frecuencia. Por otro lado, bajo condiciones de alimentación por inversor los patrones de fallo de un MI son más complicados de identificar a causa de los armónicos indeseables introducidos por ese componente [93]. En [93] los autores proponen un algoritmo capaz de separar las componentes de fallo de barra rota de la frecuencia fundamental del motor. Esta separación se consigue por medio de un muestreo no uniforme en tiempo y ha dado buenos resultados para detectar el fallo una barra rota de un MI. No obstante, aunque existen técnicas capaces de identificar la severidad de un fallo desarrollado ante condiciones transitorias, bajo diferentes situaciones de carga y de alimentación del motor, todavía no se han desarrollado técnicas que sean capaces de identificar un fallo temprano (antes de la barra rota) de manera unívoca en condiciones de alimentación por inversor.

Uno de los más destacados inconvenientes en el uso de las técnicas de detección de fallos, es la existente complejidad que entrañan para los técnicos de mantenimiento, así como su limitada versatilidad en cuanto al entorno donde operan las máquinas. En muchas ocasiones resulta muy costoso proporcionar al operador el conocimiento necesario para llevar a cabo un mantenimiento efectivo y eficaz. Para ello es importante que el usuario pueda disponer de un sistema experto o inteligente para interpretar de manera cuantitativa los resultados, permitiendo además su futura implementación en dispositivos portátiles para la recopilación de la información del estado de la máquina.

2.4. Técnicas inteligentes para diagnóstico y aprendizaje estadístico.

En la supervisión de máquinas eléctricas rotativas, los sistemas de diagnóstico basados en técnicas informáticas convencionales han sido recientemente reemplazados por nuevos sistemas basados en técnicas de inteligencia artificial debido a su eficiencia. De hecho, los sistemas tradicionales se han desarrollado sobre la base de modelos deterministas (sistemas basados en modelos) que son capaces de considerar diferentes condiciones de fallo y programar una amplia serie de condiciones operativas (ver Fig. 2.14) [94]. No obstante, la implementación de sistemas de diagnóstico basados en modelos en una sola aplicación lleva a programas complejos, difíciles de mantener y gestionar.

El término *artificial intelligence* (AI) incluye diversas técnicas tales como sistemas expertos, redes neuronales, lógica difusa y algoritmos de *machine learning* que pueden usarse de forma autónoma o combinada para mejorar su eficiencia y efectividad. Los métodos anteriores han captado la atención de muchos investigadores a pesar de que requieren de una fase de entrenamiento inicial que es crítica para una operación óptima. Siempre que la fase de entrenamiento sea posible, estas técnicas son eficientes y simples, y pueden ser adoptadas con éxito para el diagnóstico de fallos en motores eléctricos. Sin embargo, hay que tener en cuenta que las técnicas de AI sólo pueden ayudar durante el proceso de decisión y análisis, mientras que las técnicas de detección deben evaluarse independientemente [95] sobretodo cuando se dispone de poca información histórica de la máquina.

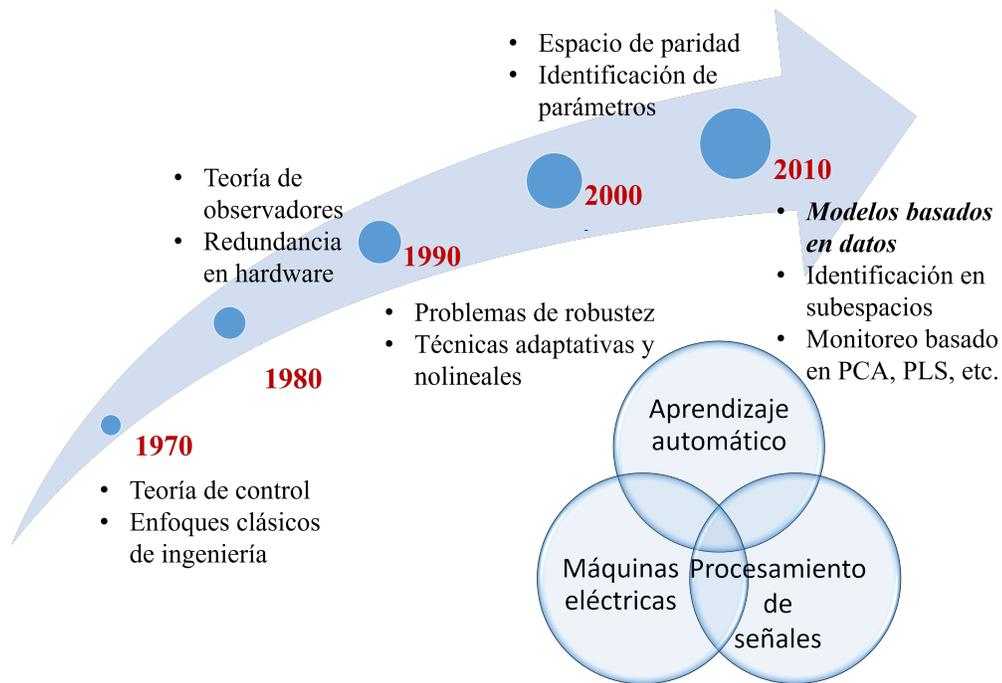


Figura 2.14: Evolución histórica de las técnicas de detección y diagnóstico de fallos.

Las técnicas de AI pueden ayudar a acelerar el proceso de decisión con una intervención humana reducida. Estas técnicas emplean algoritmos de diversa naturaleza, las cuales tienen como denominador común el uso de datos históricos recolectados de forma rutinaria a través de computadoras de proceso que facilitan su análisis rápido y automático. De forma general, los métodos de aprendizaje automático se pueden relacionar con:

- Aquellos métodos que completan el vacío del conocimiento existente.
- Algoritmos que imitan al cerebro humano.
- Aquellos que simulan el proceso evolutivo.
- Métodos que reducen la incertidumbre.
- Métodos que hacen contraste entre antiguos y nuevos conjuntos de información.

En los próximos apartados, se presentan brevemente las técnicas más usadas para el diagnóstico inteligente de fallos en máquinas eléctricas rotativas.

2.4.1. Redes Neuronales Artificiales o *Artificial Neural Networks (ANN)*.

Las ANN imitan la estructura del cerebro humano y consisten en simples unidades aritméticas conectadas en arquitectura compleja. Son capaces de representar funciones altamente no lineales y de realizar un mapeo con múltiples entradas y salidas [96]. Al igual que la mayoría de los algoritmos, éstas aprenden a base de ejemplos o instancias. Las ANN se han aplicado extensamente en el área de la monitorización de condiciones y diagnóstico de fallos [2, 74, 97–99]. Varios investigadores las han utilizado para realizar tareas a través de diferentes enfoques [41, 95]:

- Reconocimiento de patrones, estimación de parámetros y mapeo no lineal aplicado a la monitorización de condiciones.
- Entrenamiento basado tanto en indicadores en el dominio del tiempo como en el de la frecuencia obtenidos mediante simulación y/o resultados experimentales.
- Diagnóstico no supervisado en tiempo real y en línea.
- Actualización dinámica de la estructura sin necesidad de volver a entrenar toda la red.
- Filtrar transitorios, perturbaciones y ruido;
- Predicción de fallos en etapas incipientes debido a anomalías presentes en la señal de monitorización de la máquina.
- Agrupamiento o *clustering* de las condiciones de funcionamiento en base a los tipos de fallo.

Los primeros desarrollos en técnicas de AI aplicadas al diagnóstico de máquinas eléctricas rotativas fueron resumidos en [100]. En [101], se presenta un enfoque de red neuronal con el algoritmo *Multi-Layer Perceptron* (MLP), basado en MCSA para detectar anomalías en el par de carga. En [102], los autores proponen técnicas de reconocimiento de patrones aplicadas a las mediciones de tensión y corriente. Los autores en [72], usan una ANN con patrones del dominio del tiempo y de la frecuencia para el diagnóstico de fallos en rodamientos por medio del análisis de la señal de vibración. En [99], se propone un método de redundancia analítica modelando una red neuronal. La transformada de Fourier de tiempo corto se utiliza para procesar las señales de vibración a espectros continuos para el entrenamiento del modelo de red neuronal.

2.4.2. Lógica difusa o *Fuzzy Logic*.

Por otro lado, está la lógica difusa que es una variación más poderosa de la lógica tradicional, ya que permite el uso de valores intermedios a los valores exclusivos de verdadero y falso. De esta manera, la representación del conocimiento está más cerca de la forma en la que el ser humano piensa. Los sistemas difusos son capaces de procesar variables naturales (lingüísticas) a través de reglas tipo *fuzzy if-then*. Los sistemas *fuzzy* adaptativos utilizan las capacidades de aprendizaje de las ANN o la fuerza de optimización de los algoritmos genéticos para ajustar el conjunto de parámetros del sistema con el fin de mejorar el rendimiento de los sistemas inteligentes, basándose en el conocimiento *a priori*. Los sistemas adaptativos de lógica difusa se han aplicado al diagnóstico de fallos en motores para las siguientes tareas [95, 103–107]:

- Evaluación de índices de desempeño utilizando variables lingüísticas.
- Predicción de funcionamiento anormal y localización de fallos en varios elementos del motor.
- Para utilizar la experiencia humana reflejada en reglas del tipo *fuzzy if-then*.
- Modelado de sistemas, mapeo no lineal y optimización de parámetros del sistema de diagnóstico a través de sistemas *fuzzy* adaptativos.
- Clasificación y prognosis de fallos.

2.4.3. Sistemas expertos o *Expert Systems*.

Los sistemas expertos representan un intento de emular el cerebro humano mediante la representación del conocimiento y los mecanismos de inferencia. Dentro de un cierto dominio del conocimiento, los sistemas expertos son capaces de realizar una toma de decisiones en un nivel de calidad similar a los expertos humanos, aunque son costosos y requieren mucho tiempo durante la evolución. Algunos trabajos de investigación dedicados a la aplicación de sistemas expertos para el diagnóstico de fallos en máquinas eléctricas rotativas han sido reportados en la literatura [108–112]. Las principales tareas que estos trabajos acometen son:

- Emular e implementar la experiencia humana.
- Construcción y actualización en línea de bases de conocimiento del sistema.
- Filtrado de señales, búsqueda de información y extracción de características.

- Gestión de datos y codificación de información en bases de conocimiento.
- Empleo de las sesiones interactivas de los usuarios.
- Construcción de la base de conocimientos a través de simulación y/o experimentos.

2.4.4. Máquinas de Soporte Vectorial o *Support Vector Machines (SVM)*.

Los SVM son un tipo de modelo estadístico o de aprendizaje supervisado que se usan frecuentemente para convertir un clasificador lineal en modelos capaces de producir fronteras de decisión no lineales. Este clasificador construye un modelo que asigna a nuevas observaciones la clase a la que corresponden por medio de un problema de optimización que trata de encontrar un hiperplano que mejor separa a las clases por medio de los datos de entrenamiento. Vapnik [113] investigó esta técnica estadística e introdujo la métrica del margen, la cual se define como la distancia entre la frontera de clasificación y la observación más cercana del conjunto de entrenamiento. El margen definido por estas observaciones puede ser cuantificado y usado para evaluar posibles modelos para su posterior maximización. Como se ha indicado, este algoritmo puede trabajar con fronteras no lineales, incrementado el espacio de características, usando funciones polinomiales cuadráticas o de mayor orden, conocido como el “truco del *kernel*”. Los *kernels* más usados son las funciones de base radial, el sigmoide y el polinomial. Este tipo de técnica puede aplicarse tanto para clasificación (biclase o multiclase) como para regresión, así también como técnica de *clustering* por medio de la versión extendida *Support Vector Clustering (SVC)*. Para la clasificación multiclase se pueden emplear las estrategias *one-against-one (OAO)* o *one-against-all (OAA)*.

El problema de optimización consiste en encontrar el margen que mejor separe ambas clases. De acuerdo a [114], y teniendo un conjunto de muestras de entrenamiento de longitud n , $(x_1, y_1), (x_2, y_2), (x_i, y_i), \dots, (x_n, y_n)$ con $x_i \in \mathbb{R}^p$ e $y_i \in \{-1, 1\}$, un hiperplano genérico $h(x) = 0$, para separar los datos proporcionados y por tanto optimizar tal problema, puede ser definido como (2.30):

$$\min \frac{1}{2} \|\beta\|_2 + C \sum_{i=1}^n \xi_i \quad (2.30)$$

sujeto a:

$$\begin{cases} y_i(\beta^T x_i + \beta_0) \geq 1 - \xi_i \\ \xi_i \geq 0, \end{cases} \quad i = 1, 2, \dots, N \quad (2.31)$$

donde β^T es un vector de peso dimensional; β_0 es un escalar llamado *bias*; C es una constante que representa el parámetro de ajuste conocido como coste y ξ_i son las variables de holgura.

El valor de ξ_i en la restricción de (2.31) es la cantidad proporcional para la cual la predicción está en el lado incorrecto de su margen. Por lo tanto, al limitar la sumatoria limitamos la cantidad proporcional total de las predicciones que caen en el lado erróneo de su margen. El problema de optimización anterior puede ser expresado en términos de los multiplicadores de Lagrange, como (2.32):

$$L(\lambda) = \sum_{i=1}^N \lambda_i - \frac{1}{2} \sum_{i,j=1}^N y_i y_j \lambda_i \lambda_j x_i^T x_j \quad (2.32)$$

sujeto a:

$$\begin{cases} 0 \leq \lambda_i \leq C \\ \sum_{i=1}^N \lambda_i y_i = 0, \quad i = 1, 2, \dots, N \end{cases} \quad (2.33)$$

y maximizando (2.32), el problema de optimización puede ser resuelto en la etapa de entrenamiento del SVM [115].

En la literatura del área, se pueden encontrar varios trabajos que emplean este tipo de algoritmo. En [116] se hace uso de cuatro SVM y un sensor de vibración para el desarrollo de una herramienta de diagnóstico online. En [117] emplean un método combinado de *wavelets* (para la construcción del *kernel*) y SVM para la detección y diagnóstico de fallos en MIs. Las características más útiles para la etapa de clasificación son escogidas por medio de la técnica de análisis de componentes principales o *Principal Component Analysis* (PCA) como es conocida en inglés. Los autores en [118] analizan la señal transitoria de arranque de la corriente estatórica para el diagnóstico con SVM. Los patrones de fallos se obtienen con la *Discrete Wavelet Transform* (DWT). Después, los patrones más útiles para la clasificación se escogen tanto con la técnica *Independent Component Analysis* (ICA) como con PCA.

2.4.5. Análisis Lineal Discriminante o *Linear Discriminant Analysis* (LDA).

El LDA es un método utilizado en estadística, reconocimiento de patrones y aprendizaje automático para encontrar una combinación lineal de rasgos que caracterizan o separan dos o más clases de objetos o eventos. La combinación resultante puede ser utilizada como un clasificador lineal [114], o también para la reducción de la dimensionalidad antes de la etapa de clasificación de manera semejante a como lo hace el PCA. Sin embargo, mientras que el LDA intenta modelar explícitamente la diferencia entre las clases de datos, el PCA no tiene en cuenta las diferencias que se presentan entre las clases. El LDA está estrechamente relacionado con el análisis de varianza (ANOVA) y el análisis de regresión, el cual también

intenta expresar una variable dependiente como la combinación lineal de otras características. Sin embargo, ANOVA usa variables independientes categóricas y una variable dependiente continua, mientras que el LDA tiene variables independientes continuas y una variable dependiente categórica (la etiqueta de clase).

El uso de estas técnicas estadísticas ha servido para analizar y estudiar las firmas de fallo. En [119] se realiza una clasificación de fallos de barra rota a través de la técnica LDA. Las características extraídas tanto en el dominio del tiempo como en el de frecuencia son reducidas acorde a la información que aportan con PCA. En [120], se estudian las firmas de fallo LSH y RSH para comprobar si éstas son adecuadas para diagnosticar fallos de rotor en MI en estado estacionario alimentados por varias fuentes de tensión. Los autores emplean ANOVA y modelos aditivos para realizar el análisis y concluyen que, el tipo de motor, el suministro de tensión y la carga conectada al mismo influyen en la tarea de diagnóstico, siendo el suministro de tensión el factor más importante a tener en cuenta.

2.4.6. K-vecinos más cercanos o *K-Nearest Neighbors (K-NN)*.

El clasificador K -NN (Hodges, 1951) es una técnica no paramétrica que no requiere de conocimiento previo sobre la distribución de probabilidad del problema de clasificación. Esto es particularmente decisivo para aquellos casos donde las distribuciones gaussianas de las muestras sea difíciles de asumir y es importante cuando el conjunto de entrenamiento es pequeño [121]. El método K -NN clasifica una observación desconocida de acuerdo a la distancia entre ella misma y sus k muestras de entrenamiento de alrededor. Si la mayoría de las muestras más cercanas a la muestra que se trata de identificar son de una determinada clase, ésta será asignada a esa clase. Varios tipos de métricas de distancia pueden ser consideradas a efectos de modelado. Su idoneidad depende de la naturaleza de los datos, si son discretos o continuos [114]. También es importante estandarizar las variables o características antes de ser usadas por el algoritmo, ya que es muy frecuente que estén expresadas en diferentes unidades de medida.

Siendo D el conjunto de entrenamiento con n muestras t_i y, D_i el subconjunto de muestras pertenecientes a la clase c_i y dada una muestra de test x , y siendo k el número de vecinos considerado, r la distancia de x a sus k vecinos más cercanos en \mathbf{D} , la hiperbola de dimensión d y radio r alrededor de la muestra de test es definida como:

$$\mathbf{B}_d(x, r) = \{t_i \in \mathbf{D} \mid \delta(x, t_i) \leq r\}, \quad (2.34)$$

donde $\delta(x, t_i)$ es la distancia entre x y t_i , definida por alguna de las métricas de distancia. Asumiendo que

$$|\mathbf{B}_d(x, r)| = k, \quad (2.35)$$

y denotando como k_i el número de muestras entre los k vecinos más cercanos de x etiquetados con clase c_i , la densidad de probabilidad condicional en x puede ser estimada como:

$$\hat{f}(x | c_i) = \frac{k_i}{n_i V}, \quad (2.36)$$

donde V es el volumen de la hipérbola de dimensiones d . Por tanto, del Teorema de Bayes, la probabilidad *a posteriori* de una muestra del conjunto de test puede ser estimada por:

$$\hat{f}(x | c_i) = \frac{k_i}{n_i V}. \quad (2.37)$$

A pesar de su simplicidad, K -NN ha sido usado satisfactoriamente para la clasificación de fallos en MIs [122]. En [123] se comparan varias técnicas de aprendizaje supervisado: K -NN, LDA y SVM para su aplicación al diagnóstico de fallos en el rotor de un turbo-generador. En [124], se desarrolla un sistema de sensores inteligentes que adquiere tres tipos de señales: vibración, corriente y flujo. Posteriormente, emplean los algoritmos SVM, LDA, K -NN y *Random Forest* (RF) como clasificadores para el diagnóstico de fallos. Los parámetros de estos clasificadores se optimizan mediante el método de validación cruzada (VC). En [122] se presenta una evaluación exhaustiva de varios métodos de clasificación de patrones para la identificación de fallos en el estátor de un MI. Los métodos discutidos en ese trabajo son: Naive Bayes (NB), K -NN, SVM (Optimización Mínima Secuencial), ANN (MLP), y los Árboles de Decisión (C4.5).

2.4.7. Árboles de decisión o *Decision Trees* (DT).

Este tipo de técnicas permite construir conjuntos de reglas jerárquicas en forma de árbol para proporcionar explicaciones y facilitar la interpretación de sus predicciones. El árbol de decisión (DT) predice los datos de salida en base a los datos de entrada (vectores de características). Existen varias clases de algoritmos y pueden ser usados tanto para construir modelos de regresión como de clasificación [114]. La decisión final viene indicada por los nodos hoja y se alcanzan en base a las reglas previamente construidas y seguidas antes de llegar a éstos. De manera general, los pasos requeridos para construir el clasificador son los siguientes:

1. Se analizan todos los vectores de características de entrada y se examinan todas las divisiones binarias posibles.
2. Se seleccionan aquellas divisiones con mejor índice o criterio de optimización.
3. Se repite el proceso para los dos nodos obtenidos.
4. El proceso de partición se detiene cuando un nodo contiene únicamente observaciones de una clase.

Varios trabajos de la literatura han empleado este tipo de algoritmos. Autores en [107], presentan un método de diagnóstico basado en un sistema de inferencia *neuro-fuzzy adaptativa* (ANFIS) combinado con árboles de decisión tipo *Árbol de Clasificación y Regresión (CART)* para la selección de las características más relevantes para la clasificación de los datos. Los parámetros de las funciones de pertenencia a cada clase (estados del motor) son ajustados de manera híbrida con el algoritmo de retropropagación y por medio de mínimos cuadrados. Los autores emplean tanto señales de vibración como de la corriente del estátor para diferenciar hasta 8 tipos de defectos. En [125] se describe un modelo híbrido de aprendizaje en línea que combina la red neural *fuzzy* min-max (FMM) y el árbol CART para tareas de detección y diagnóstico de fallos en motores. El modelo híbrido, conocido como FMM-CART, incorpora las ventajas de FMM y CART para realizar la clasificación de datos (con FMM) y para la extracción de reglas (con CART).

2.4.8. Otras técnicas de diagnóstico de fallos.

Otra técnica usada en diagnóstico de fallos de motores es el algoritmo RF. RF (Leo Breiman 2001) puede ser usado tanto para regresión como para clasificación. Éste consiste en la construcción de un bosque de árboles no correlacionados utilizando un procedimiento similar a CART, combinado con la optimización de nodos aleatorios y *Bagging* [114]. Las principales características que tiene son:

- El error de generalización se estima mediante el error fuera de bolsa (*out-of-bag*).
- La importancia de cada variable se mide a través de la permutación.

Esto permite evitar el sobreajuste que cometen los árboles de decisión ya que con *Bagging* se mejora la varianza con pocos parámetros de ajuste [114].

Algunos investigadores en el área han usado esta técnica. Patel *et al.* [126] realizan una selección de características y clasificación de fallos mecánicos a través del algoritmo RF.

En [127] los autores exploran el potencial de RF para el diagnóstico de fallos y proponen un método híbrido con algoritmos genéticos.

Finalmente, se debe indicar que otras técnicas como Naive-Bayes (NB) y la Regresión Logística (RL) también se han usado para el diagnóstico de fallos en máquinas eléctricas rotativas [2, 122].

Como se puede apreciar de este repaso de la literatura del área, un número importante de técnicas de diagnóstico inteligente han sido publicadas recientemente. No obstante, muchas de las metodologías desarrolladas emplean conjuntos de datos relativamente grande, lo cual no siempre es sinónimo de buenos resultados, omitiendo aspectos importantes en la construcción de estos sistemas que se comentan a continuación.

2.5. Oportunidades y conclusiones.

En este apartado se resumen las conclusiones extraídas del estudio del estado del arte para presentar de forma concreta las oportunidades que han motivado el desarrollo de esta tesis doctoral.

2.5.1. Desarrollo de características para el análisis de señales ruidosas.

Una de las principales necesidades que requieren atención es el desarrollo de herramientas de diagnóstico útiles para motores alimentados por inversor que permitan llevar a cabo una identificación temprana de fallos no catastróficos como lo es el fallo de barra rota de un MI. Para ello, una de las principales actividades será identificar y/o diseñar patrones de fallo fiables para realizar una monitorización basada en la corriente estática que, aprovechando las ventajas que tiene esta técnica, ofrezca baja sensibilidad al ruido que introduce el elemento inversor en esta señal.

2.5.2. Evaluación y diseño de la herramienta de diagnóstico en contextos reales.

Otro de los aspectos críticos a tener en cuenta, será la construcción del sistema supervisado de diagnóstico. Normalmente se necesita un conjunto de datos relativamente elevado que contenga indicadores relativos a todos los estados que se quieran detectar. Resulta complicado construir un buen conjunto de datos, puesto que en la realidad se dispondrá de muchos datos del sistema en estado sano y pocos datos del sistema en condiciones de fallo. Disponer de

muchos datos del motor con fallo puede ayudar a construir el sistema de diagnóstico, pero introduce un bias que puede dar lugar a una alta tasa de falsos positivos (entendiendo por positivo el fallo). Por el contrario, emplear pocos datos del motor en estado de fallo puede reducir las prestaciones del algoritmo, produciendo una tasa de falsos negativos alta y, por tanto, dificultando la detección del fallo. La metodología propuesta tratará de solventar los inconvenientes de los sistemas de diagnóstico actuales presentados a continuación.

2.5.2.1. Aprovechamiento de la información ante desequilibrios de clase.

El uso de modelos físicos para construir herramientas de diagnóstico simplifica en exceso la realidad y hace que nos resulte más útil el manejo de la información. Por ello, las técnicas basadas en datos mejoran la capacidad de diagnóstico de un sistema ya que tienen en cuenta aspectos no considerados en la etapa de diseño de los modelos, que perturban las magnitudes de la máquina. Sin embargo, herramientas que requieren muchas observaciones para la construcción del clasificador incurren en costes innecesarios que no mejoran las prestaciones de la clasificación. Consecuentemente, en la fase de diseño de una herramienta de diagnóstico de fallos basada en datos, deben tenerse en cuenta aspectos como el tamaño de los conjuntos de datos y el desequilibrio entre las clases. El entrenamiento de clasificadores con conjuntos de datos que sufren desequilibrio en las distribuciones de clase, es un problema importante en las técnicas de aprendizaje automático [128]. Este problema se produce cuando el número de ejemplos que representan la clase de interés (clase de fallo) es mucho menor que el de la otra clase (clase motor sano). Este problema acontece en muchas aplicaciones del mundo real y ha atraído la atención de investigadores en muchas áreas. Sin embargo, en el campo del diagnóstico de fallos en máquinas eléctricas no se han desarrollado metodologías que aborden esta temática.

2.5.2.2. Necesidad de evaluar correctamente las prestaciones de los algoritmos.

Para hacer frente a los desafíos del diagnóstico, la medicina y la biología han desarrollado técnicas estadísticas sofisticadas. Sin embargo, incluso en campos como éstos, hay mucho espacio para los errores y malas interpretaciones [129,130] cuando se trata de evaluar las prestaciones del clasificador. Por ello, el diagnóstico de máquinas eléctricas rotativas es también un campo vulnerable a este tipo de problemática. Un aspecto a considerar es el problema de elegir un algoritmo o combinación de algoritmos adecuada para la fase de diagnóstico, de acuerdo a un desempeño predictivo razonable. En otras ocasiones, simplemente se desea realizar una implementación viable del clasificador para evitar el uso superfluo de recursos a

igualdad de prestaciones. Durante el estudio de la literatura, se ha comprobado que existe una necesidad de encontrar un procedimiento válido para evaluar el rendimiento del clasificador que atienda los siguientes aspectos:

- Estudio de las métricas más adecuadas que extraigan información de cómo se clasifica cada una de las clases.
- Empleo de las técnicas de estimación del error más adecuadas para optimizar adecuadamente los parámetros de ajuste del clasificador.
- Aplicación de las pruebas más oportunas para confirmar la significancia estadística de los resultados obtenidos.

Capítulo 3

Marco teórico.

En este capítulo se explica la influencia que tienen los armónicos generados por un inversor en el estudio de los patrones de fallo de barra rota de un MI. Además, se presentan las técnicas de filtrado usadas para minimizar los efectos de los armónicos, así como las características o patrones que han sido empleados y obtenidos para la construcción de la herramienta de diagnóstico. Finalmente, se hace un repaso de las técnicas existentes para llevar a cabo una evaluación adecuada del clasificador que se pretende diseñar.

3.1. Alimentación de un MI por inversor.

Recientemente se ha observado que el diagnóstico de fallos en MI alimentados por inversor trae consigo importantes complicaciones. El uso de inversores también conocidos como convertidores de potencia, convertidores de frecuencia, variadores de frecuencia, etc. hace que muchas de las técnicas que funcionaban correctamente para diagnosticar motores alimentados directamente desde la red, no arrojen los mismos resultados en los casos de alimentación por inversor. Por ello, a continuación se estudia esta problemática y se presentan los aspectos a tener en cuenta para su análisis.

La principal ventaja de un MI respecto a un motor síncrono, es la posibilidad de accionarlo directamente de la red sin necesidad de otros sistemas de excitación. Además, también presenta ventajas respecto de los motores de corriente continua, ya que no requiere adaptar la tensión de alimentación. Por ello, antes de la introducción de los inversores para la regulación de la velocidad de los MI ésta se hacía [131]:

- Modificando el número de polos del motor.

- Insertando resistencias adicionales en el devanado secundario.
- Controlando la tensión de línea con conexiones estrella-triángulo.

Sin embargo, los inconvenientes de los mecanismos de regulación asociados a estos factores, unido a las ventajas de los motores de corriente continua, hacían que fueran descartados para aplicaciones de velocidad variable. Por ello, no fue hasta la aparición de los inversores, cuando los MI empezaron a tomar mayor protagonismo.

En general, los inversores transforman la energía eléctrica de entrada, de unos valores de frecuencia y amplitud determinados por la red, en energía eléctrica de salida con una frecuencia y amplitud asignada por el usuario. La regulación se lleva a cabo por medio de un algoritmo de control que genera las órdenes de mando acorde a las consignas de entrada. El usuario puede establecer la velocidad de consigna a través de alguno de los siguientes procedimientos de control:

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

Estas estrategias de control son desarrolladas por medio de sensores, reguladores y microprocesadores entre otros elementos. Las más usadas en la industria son las primeras seguidas de las segundas [132]. Los inversores suponen una mejora en el rendimiento energético, un control más preciso de la velocidad y del arranque, así como una disminución de la corriente de arranque. A pesar de ello, presentan el inconveniente de introducir armónicos temporales e interarmónicos en la corriente de alimentación del motor, dificultando la tarea de detección y diagnóstico de fallos.

3.1.1. Estructura de un inversor.

Para poder realizar un diagnóstico adecuado en MI alimentados por inversor, hay que entender cómo es el funcionamiento de un inversor. Los inversores empleados en la industria constan de varias etapas [29] (ver Fig. 3.1):

- Etapa rectificadora. La tensión alterna de la red se rectifica a continua a través un puente no controlado de diodos.
- Bus de continua. La señal rectificada se filtra para eliminar el rizado de la tensión creado por el rectificador.
- Etapa inversora. La señal ya filtrada se invierte de nuevo a corriente alterna. Esta etapa está construida y controlada con transistores bipolares de puerta aislada (IGBT).

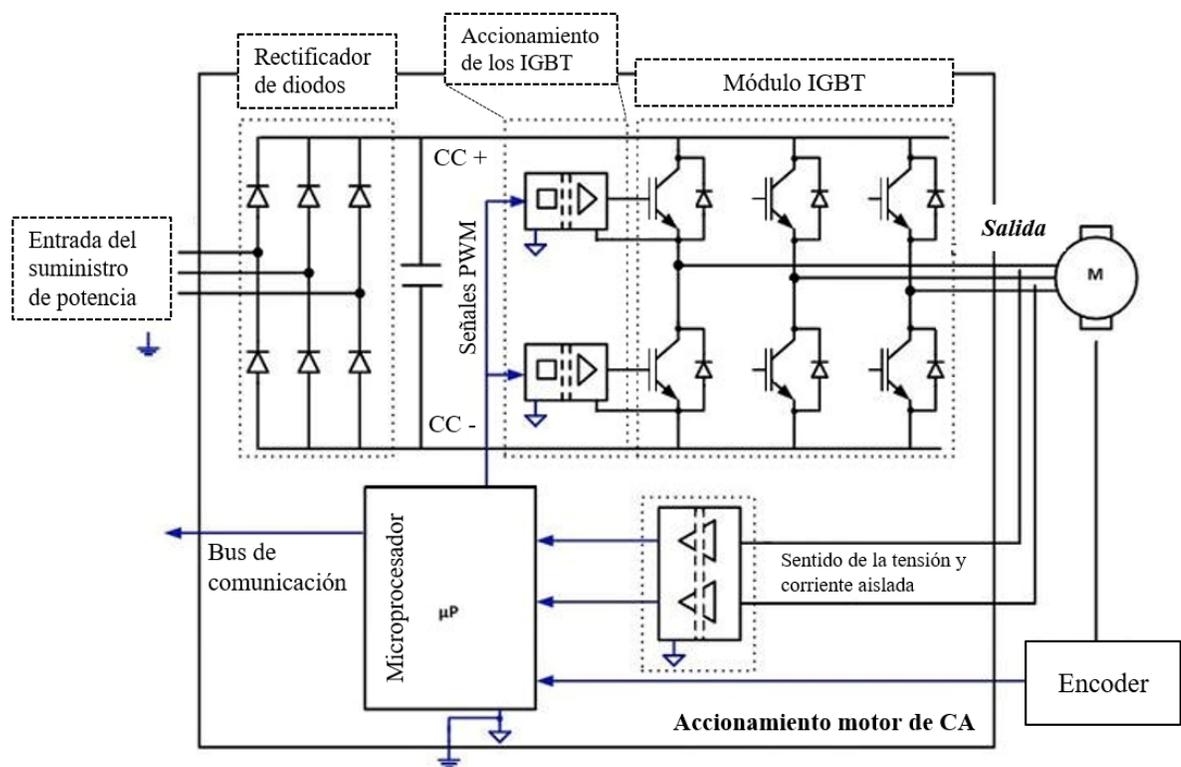


Figura 3.1: Accionamiento de un MI con inversor.

3.1.2. Inversor de tensión de dos niveles.

La técnica de modificación de la amplitud y frecuencia conocida como modulación del ancho de pulso (PWM) en inversores de dos niveles es la más común a nivel comercial. La

técnica PWM es la que gobierna los tiempos de apertura y cierre de los IGBT, representados en la Fig. 3.1. Dependiendo del nivel de la tensión de continua, se pueden adicionar varios de estos elementos en serie. Cada fase de la carga trifásica se conecta al punto intermedio de cada una de estas ramas como se muestra en la Fig. 3.1. La técnica PWM usa dos ondas para generar las señales de mando de los IGBT. Las señales de mando son una serie de pulsos generados al comparar la onda portadora (por lo general con forma triangular), con una onda moduladora (con forma senoidal y frecuencia la deseada). Cuando se trata de alimentar una carga trifásica se generan tres ondas moduladoras, una por cada fase, desfasadas 120° entre sí. Los parámetros que permiten controlar la generación de tensión requerida por la aplicación son [133]:

1. Índice de modulación de amplitud, m_a definido como:

$$m_a = \frac{V_m}{V_{cr}} \quad (3.1)$$

2. Índice de modulación de frecuencia, m_f definido como:

$$m_f = \frac{f_{cr}}{f_m} \quad (3.2)$$

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

El índice de modulación de amplitud controla a la componente fundamental de la tensión de salida del inversor. Generalmente, se regula el valor de la amplitud de la onda moduladora manteniendo constante el valor de pico de la onda portadora. El índice de modulación de frecuencia controla la frecuencia de la componente fundamental.

En la Fig. 3.2 se puede apreciar la generación de los pulsos de conmutación de los IGBT de un inversor de tensión de dos niveles a través de las ondas mencionadas. Las formas de onda de la parte superior muestran las tres ondas moduladoras senoidales de cada fase, siendo sus valores de pico V_{mA} , V_{mB} y V_{mC} , respectivamente. En la imagen se puede ver cómo las tres ondas moduladoras están desfasadas entre sí 120° . La portadora es una onda triangular de valor pico V_{cr} . Los IGBT son gobernados por la señal de mando que resulta de comparar la onda portadora con las ondas moduladoras. De esta manera, en la Fig. 3.2 se puede observar la forma de onda resultante, con forma de tren de pulsos de anchura variable de tres

niveles de tensión: V_d , 0 y $-V_d$. De forma superpuesta a la componente fundamental se puede apreciar la forma periódica del tren de pulsos en la misma figura. Como se ha comentado, la componente fundamental es sinusoidal y su amplitud y frecuencia se pueden regular de forma independiente a través de los índices de modulación de amplitud y frecuencia, respectivamente.

Para el caso de inversores de dos niveles, la frecuencia de conmutación (f_{sw}) de los IGBT coincide con la frecuencia de la onda portadora y se obtiene con la siguiente expresión:

$$f_{sw} = f_{cr} = m_f f_m \quad (3.3)$$

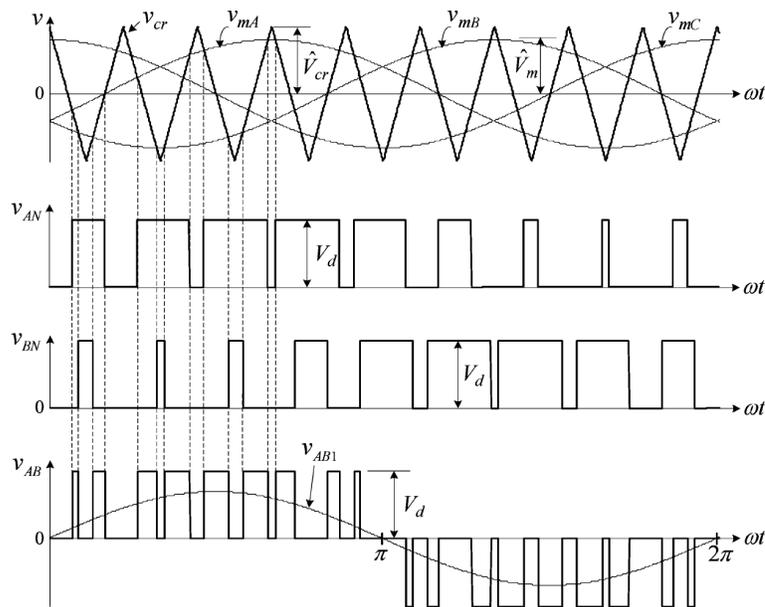


Figura 3.2: Formas de onda de un esquema PWM senoidal.

Cuando la onda portadora está sincronizada con la onda moduladora (cumple que el índice de modulación de frecuencia m_f es un número entero), el esquema de modulación se conoce como PWM síncrono. Nótese que también existen esquemas de modulación asíncronos, donde la frecuencia de la onda portadora, f_{cr} , suele ser fija y sólo se cambia el índice de modulación de frecuencia, m_f , que puede ser un número no entero. Por lo general, el esquema PWM asíncrono es más fácil de implementar con circuitos analógicos, mientras que el PWM síncrono resulta fácilmente implementado con procesadores digitales de señales. La frecuencia de conmutación puede ser fijada por el usuario, pero se ha mantenido el valor por defecto

de los diferentes inversores siendo de 4 kHz y 5 kHz, según el fabricante del dispositivo en cuestión.

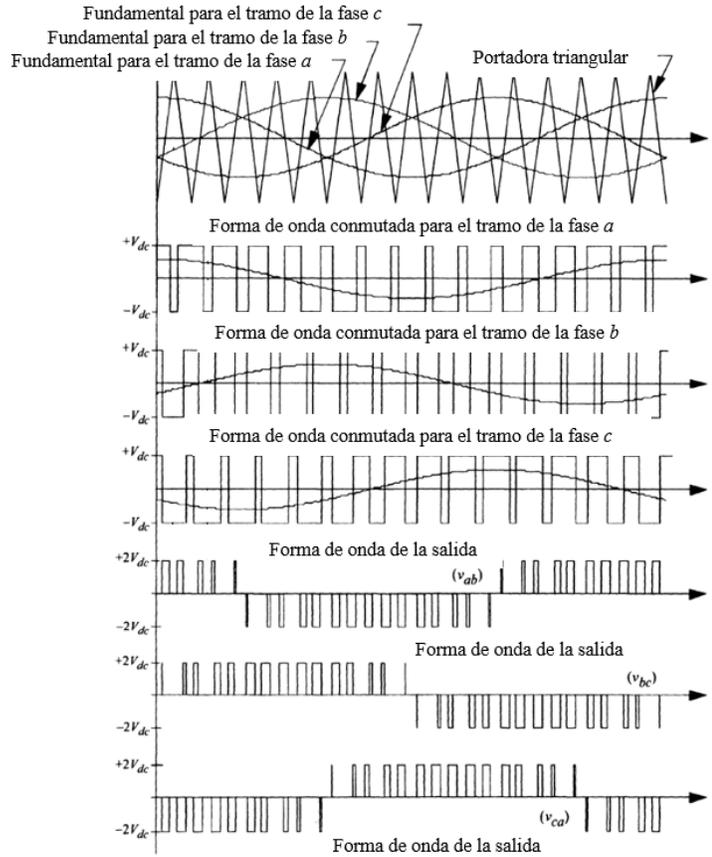


Figura 3.3: Tensiones de línea generadas según un esquema PWM senoidal para el inversor [134].

3.1.3. Contenido armónico de la señal de tensión de salida.

En la Fig. 3.3, las componentes fundamentales de las tres tensiones entre los terminales *a*, *b* y *c* y el punto medio del bus de continua (Fig. 3.1) son las siguientes [134]:

$$V_{az,1} = V_0 \cos(\omega_0 t) = MV_{dc} \cos(\omega_0 t), \quad (3.4)$$

$$V_{bz,1} = V_0 \cos\left(\omega_0 t - \frac{2\pi}{3}\right) = MV_{dc} \cos\left(\omega_0 t - \frac{2\pi}{3}\right), \quad (3.5)$$

$$V_{cz,1} = V_0 \cos\left(\omega_0 t + \frac{2\pi}{3}\right) = MV_{dc} \cos\left(\omega_0 t + \frac{2\pi}{3}\right), \quad (3.6)$$

Restando dos a dos las tensiones anteriores se pueden obtener las tensiones de línea [134] como:

$$V_{ab,1} = V_{az,1} - V_{bz,1} = M\sqrt{3}V_{dc} \cos\left(\omega_0 t + \frac{\pi}{6}\right) \quad (3.7)$$

$$V_{bc,1} = V_{bz,1} - V_{cz,1} = M\sqrt{3}V_{dc} \cos\left(\omega_0 t - \frac{\pi}{6}\right) \quad (3.8)$$

$$V_{ca,1} = V_{cz,1} - V_{az,1} = M\sqrt{3}V_{dc} \cos\left(\omega_0 t + \frac{\pi}{6}\right) \quad (3.9)$$

siendo M el índice de modulación pudiendo tomar como valor máximo la unidad. El máximo valor de pico que puede tomar la tensión de línea de salida es $\sqrt{3}V_{dc}$. Los autores en [134] exponen un procedimiento para obtener la solución armónica de las tensiones entre los terminales a , b y c respecto al punto medio del bus de continua:

$$V_{az}(t) = V_{dc} + V_{dc}M \cos(\omega_0 t) + \frac{4V_{dc}}{\pi} \sum_{m=1}^{\infty} \sum_{n=-\infty}^{\infty} \frac{1}{m} J_n\left(m\frac{\pi}{2}M\right) \sin\left([m+n]\frac{\pi}{2}\right) \cos(m\omega_{cr}t + n\omega_0 t) \quad (3.10)$$

$$V_{bz}(t) = V_{dc} + V_{dc}M \cos\left(\omega_0 t - \frac{2\pi}{3}\right) + \frac{4V_{dc}}{\pi} \sum_{m=1}^{\infty} \sum_{n=-\infty}^{\infty} \frac{1}{m} J_n\left(m\frac{\pi}{2}M\right) \sin\left([m+n]\frac{\pi}{2}\right) \cos\left(m\omega_{cr}t + n\left[\omega_0 t - \frac{2\pi}{3}\right]\right) \quad (3.11)$$

$$V_{cz}(t) = V_{dc} + V_{dc}M \cos\left(\omega_0 t + \frac{2\pi}{3}\right) + \frac{4V_{dc}}{\pi} \sum_{m=1}^{\infty} \sum_{n=-\infty}^{\infty} \frac{1}{m} J_n\left(m\frac{\pi}{2}M\right) \sin\left([m+n]\frac{\pi}{2}\right) \cos\left(m\omega_{cr}t + n\left[\omega_0 t + \frac{2\pi}{3}\right]\right) \quad (3.12)$$

siendo:

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

La tensión de línea entre los terminales a y b se obtiene como [134]:

$$\begin{aligned}
 V_{ab}(t) = V_{az}(t) - V_{bz}(t) = & \sqrt{3}V_{dc}M \cos\left(\omega_0 t + \frac{\pi}{6}\right) + \\
 & + \frac{8V_{dc}}{\pi} \sum_{m=1}^{\infty} \sum_{n=-\infty}^{\infty} \frac{1}{m} J_n\left(m\frac{\pi}{2}M\right) \\
 & \cdot \sin\left([m+n]\frac{\pi}{2}\right) \sin\left(n\frac{\pi}{3}\right) \cos\left(m\omega_{cr}t + n\left[\omega_0 t + \frac{\pi}{3}\right] + \frac{\pi}{2}\right)
 \end{aligned} \tag{3.13}$$

Observando la ecuación (3.13), el principal contenido armónico viene descrito por la frecuencia fundamental ω_0 . La doble sumatoria describe el resto de armónicos. Los factores que determinan la amplitud del armónico son la función de Bessel y los dos senos independientes del tiempo. Nótese por ejemplo que los armónicos triples se cancelan a causa del factor $\sin\left(\frac{n\pi}{3}\right)$. Además, todos los armónicos pares donde la combinación $(m+n)$ es múltiplo de 2 también se cancelan. Las frecuencias de los armónicos presentes en la señal serán múltiplos de la frecuencia de la onda portadora $\omega_{cr}(m \geq 1)$. Obsérvese que n toma valores enteros positivos y negativos en el rango $-\infty$ a $+\infty$.

Como ejemplo, en la Fig. 3.4 se puede observar algunos resultados teóricos para las siguientes condiciones:

- Índice de modulación de amplitud: 0.8.
- Índice de modulación de frecuencia: 15.
- Frecuencia fundamental: 60 Hz.
- Frecuencia de conmutación: 900 Hz.
- Carga trifásica inductiva con factor de potencia: 0.9.

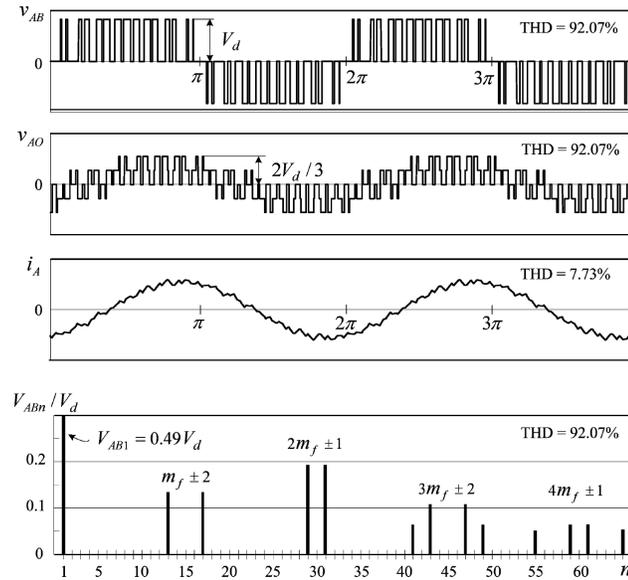


Figura 3.4: Tensión de línea y fase-neutro (neutro real de la carga) para una carga inductiva con factor de potencia 0,9 y con las siguientes condiciones: $m_a = 0,8$, $m_f = 15$, $f_0 = 60Hz$ [133].

Por otro lado, en la Fig. 3.5 se presenta la dependencia del contenido armónico de la tensión de línea con diversos parámetros.

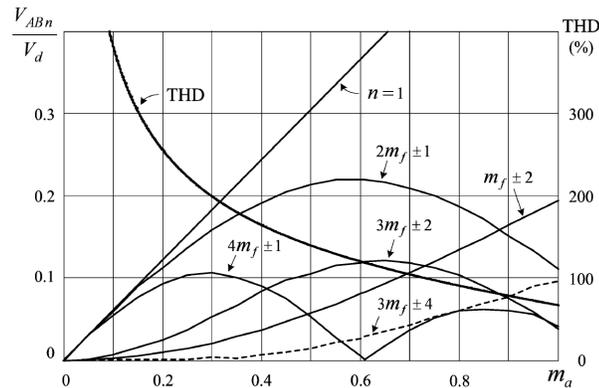


Figura 3.5: Contenido armónico de la tensión de línea para las condiciones de la Fig. 3.4 [133].

3.1.4. Otro contenido armónico.

Existen fenómenos como la sobremodulación que pueden provocar la aparición de armónicos de orden inferior, como pueden ser el 5^o y 11^o [2]. Otra técnica alternativa a la sobremo-

dulación consiste en añadir un tercer armónico. La adición de un tercer armónico consiste en modificar la onda moduladora (V_{mA}) añadiendo a la componente fundamental (V_{m1}) otra onda con frecuencia triple (V_{m3}) y amplitud inferior, como se muestra en la Fig. 3.6. Con la adición de un tercer armónico se consigue suavizar, en cierta manera, la onda moduladora en la parte central del semiciclo.

Los autores en [135] demuestran que pueden llegar a aparecer interarmónicos, es decir, armónicos no enteros de la frecuencia fundamental y de la frecuencia portadora, incluso por debajo de la frecuencia fundamental complicando su filtrado. En el citado trabajo, se indica que el origen de dichos interarmónicos depende principalmente del sistema de control.

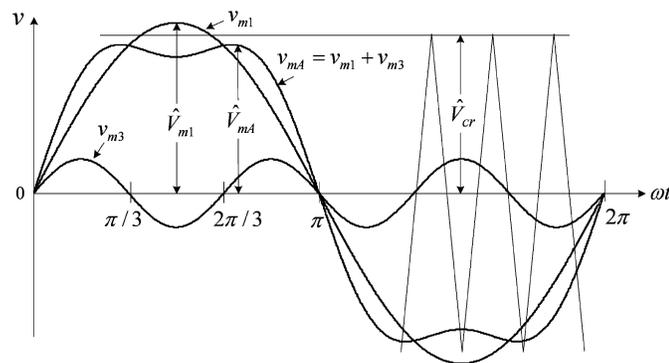


Figura 3.6: Inyección del tercer armónico en onda moduladora [134].

3.1.5. Efectos del uso del inversor en el sistema motor más inversor.

Como se ha analizado, un inversor genera una tensión de alimentación del motor que presenta un alto contenido armónico, incluso a frecuencias relativamente altas. Como es de esperar, la presencia de armónicos dependerá del esquema de modulación PWM y la estrategia de control seleccionada [133, 134] y está caracterizada de manera diferente según cada fabricante.

A pesar de las ventajas que tiene el empleo de los inversores, éstos presentan inconvenientes al aplicar las técnicas de diagnóstico propuestas hasta la fecha. Cuando se emplea un inversor para alimentar un MI, los principales efectos adversos que se presentan son [2]:

- Aparición de pares pulsantes y resonancias que pueden acelerar el fallo por fatiga del material del rotor, reducir su vida útil, y producir fallos en rodamientos o bloqueos

mecánicos del motor [136–138].

- El motor va a producir mayores vibraciones mecánicas dando lugar a su vez a mayores emisiones acústicas a las cuales va a estar sometido [136–139].
- El motor va a sufrir un mayor calentamiento producido por el efecto Joule adicional originado por las nuevas componentes espectrales.
- El aislamiento eléctrico de los conductores va a sufrir gradientes elevados de tensión que pueden dañar el estátor de la máquina [140].

3.1.5.1. Alteración de los patrones de fallo por el uso de inversor.

En el campo del diagnóstico de fallos de máquinas eléctricas rotativas, la aparición del inversor ha supuesto un cambio significativo. Con él se presentan nuevos retos que necesitan ser investigados para lograr desarrollar herramientas de diagnóstico efectivas. Los principales retos que surgen son los siguientes [141]:

- Mayor contenido de ruido en la señal estatórica. Al aplicar una técnica de análisis espectral, como por ejemplo la FFT, se puede apreciar un mayor nivel de ruido. Esto puede reducir la posibilidad de reconocer las firmas de fallo características de un MI [142, 143]. Claro está que el nivel de ruido dependerá del tipo de inversor, fabricante, estrategia de modulación, esquema de control, etc. En la Fig. 3.7 se puede observar la forma de onda y el espectro de la tensión de línea de un MI sano, alimentado directamente de la red ante condiciones de funcionamiento en vacío. En cambio, en la Fig. 3.8 [32] se representa exactamente lo mismo, pero para un MI alimentado por un inversor con frecuencias de consigna de 35 y 65 Hz. Observando ambos casos se aprecia el incremento del césped o nivel ruido.
- Otro reto es la posible variación dinámica de la frecuencia fundamental. Esto es crítico cuando se emplean técnicas de análisis espectral que requieren de un periodo de tiempo relativamente largo donde se producen ligeros cambios en el régimen de funcionamiento. Hay que recordar que el objetivo de emplear un inversor es ajustar el par y/o velocidad desarrollado por el motor a los requerimientos de la carga. En función de la aplicación, el inversor irá ajustando continuamente la frecuencia (y amplitud de salida si fuere el caso), de acuerdo con su tipo de control y según los requerimientos de la carga. Hoy día, muchos inversores tienen la opción de compensación por deslizamiento que

incrementa la frecuencia de salida del inversor si aumenta la carga del motor. Es decir, intentan mantener constante la velocidad de giro de la máquina aún cuando implique modificar la frecuencia de consigna. De esta forma, una frecuencia de consigna de 50 Hz puede verse incrementada si el algoritmo de control, aunque sea en lazo abierto, detecta un deslizamiento elevado. El control decide incrementar la frecuencia por ejemplo a 51,5 Hz, para compensar en la velocidad ese incremento del deslizamiento [32]). Estos cambios son más acusados si el control del inversor es en lazo cerrado, llegando incluso a suprimir o atenuar en el espectro algunas frecuencias características de ciertos tipos de fallos [144–146].

- Bajo ciertos modos de control (Control vectorial, etc.) el inversor introduce interarmónicos que pueden dificultar la observación de los patrones de fallo [147]. Estos interarmónicos pueden aparecer muy próximos a los patrones característicos de barra rota en el espectro y dar lugar a falsos positivos.

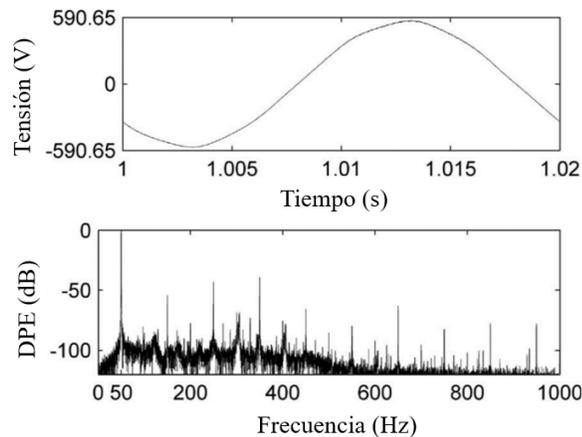


Figura 3.7: Contenido armónico de la tensión de línea: alimentación directa de red (Motor sano en vacío) [32].

A pesar de que ya se han presentado algunos trabajos en este área [16, 120, 148, 149] se requiere una mayor profundización para resolver muchos de los retos que todavía están presentes [95, 142] para mejorar el diagnóstico de fallos incipientes en MI alimentados por inversor.

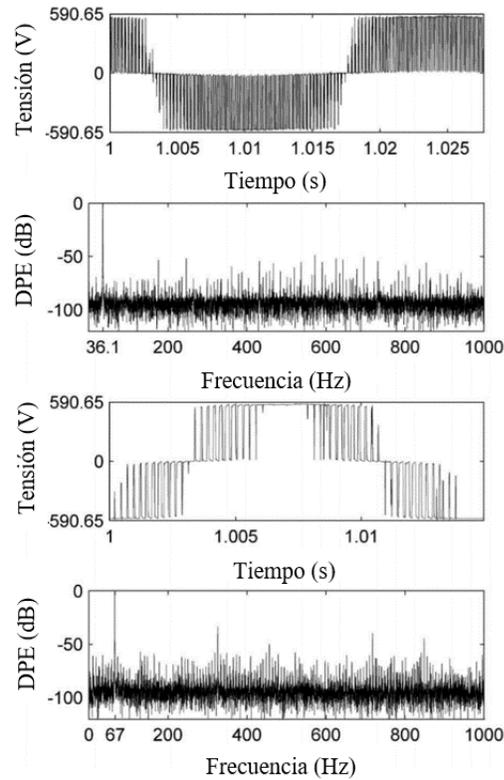


Figura 3.8: Contenido armónico de la tensión de línea: alimentación con variador Siemens (Micro-Master 420), con una frecuencia de consigna de 35 Hz (arriba) y con una frecuencia de consigna de 65 Hz (abajo). Motor sano y en vacío [32].

Para superar los inconvenientes en los sistemas inversor-motor, es necesario ampliar el número de patrones a monitorizar (tanto en el dominio de la frecuencia como en el temporal) con el objetivo de asegurar una mayor eficacia en el diagnóstico [95, 120, 142].

3.2. Tratamiento de la señal con alto contenido armónico.

En el apartado anterior, se ha visto que cuando un MI es alimentado por un inversor, éste introduce contenido armónico diverso. Para aminorar los efectos de los armónicos insertados por el inversor existen técnicas de filtrado digital que permiten observar con más claridad las frecuencias relacionadas con el fallo. Un filtro digital es un algoritmo matemático, implementable en hardware, que opera sobre una señal digital de entrada, cambiando de manera

selectiva la forma de onda o las características amplitud-frecuencia o fase-frecuencia según los requerimientos del uso de la señal de salida. En la Fig. 3.9 se puede ver un diagrama simplificado de los bloques que componen un filtro digital que opera en tiempo real con entradas y salidas analógicas. La señal de entrada, limitada en banda, se muestrea con una frecuencia adecuada para obtener las muestras requeridas de la señal. El procesador digital de señales opera y convierte una sucesión de muestras de la señal de entrada en una sucesión de muestras de la señal de salida por medio del algoritmo matemático previamente diseñado. Las principales ventajas que han dado preferencia al uso de filtros digitales respecto al filtrado analógico son las siguientes:

- Los filtros digitales tienen un desempeño independiente de las condiciones ambientales y pueden tener características que con los filtros analógicos sería imposible conseguir (por ejemplo respuesta de fase lineal en filtros FIR, etc.).
- Un filtro digital puede procesar varias señales de entrada sin necesidad de replicar hardware.
- Las señales filtradas y sin filtrar pueden almacenarse para su posterior análisis.
- Su desempeño es repetible de unidad a unidad y pueden utilizarse a muy bajas frecuencias, incluso en un amplio rango de frecuencias con sólo modificar la frecuencia de muestreo.

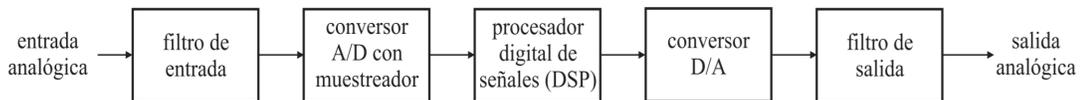


Figura 3.9: Diagrama de bloque básico de un filtro digital.

El diseño de filtros en tiempo discreto consiste en determinar los parámetros de una función de transferencia (FT) o ecuación en diferencias que aproxime la respuesta al impulso deseada o que la respuesta en frecuencia permanezca dentro de un rango específico de tolerancias. Los sistemas discretos implementados con ecuaciones en diferencias pueden ser de respuesta infinita al impulso (IIR) o de respuesta finita al impulso (FIR) [150].

Una forma de caracterizar matemáticamente un sistema (lineal e invariante en el tiempo)

realizable, de filtrado digital es por medio de su FT [151]:

$$H(z) = \frac{P(z)}{Q(z)} = H_0 \frac{(z - z_1) \cdot (z - z_2) \cdot \dots \cdot (z - z_m)}{(z - p_1) \cdot (z - p_2) \cdot \dots \cdot (z - p_n)}, \quad (3.14)$$

donde las raíces de $P(z)$ son llamadas ceros de la FT, y las raíces de $Q(z)$ polos de la FT, siendo ambos conjuntos referidos colectivamente como frecuencias críticas. Los polos pueden ser localizados a través de expresiones explícitas o por medio de métodos numéricos. La localización de los polos de la FT describe, entre otras cosas, la estabilidad del sistema.

La respuesta de un sistema en estado estacionario se puede determinar tan sólo evaluando la función de transferencia $H(s)$ a la frecuencia compleja $s = j\omega$:

$$H(j\omega) = |H(j\omega)| \cdot e^{j\theta(\omega)} = H(s)|_{s=j\omega}. \quad (3.15)$$

La respuesta en magnitud de un sistema descrito por su FT, $H(j\omega)$ es:

$$|H(j\omega)| = \sqrt{\Re[H(j\omega)]^2 + \Im[H(j\omega)]^2}. \quad (3.16)$$

A su vez, la respuesta de fase es el arco tangente del cociente entre la parte imaginaria y la parte real de la respuesta en estado estacionario:

$$\theta(\omega) = \arctan \left(\frac{\Im[H(j\omega)]}{\Re[H(j\omega)]} \right). \quad (3.17)$$

Con la respuesta de fase expresada en (3.17), el retardo de fase $\tau_f(\omega)$ de un sistema puede ser definido como:

$$\tau_f(\omega) = \frac{-\theta(\omega)}{\omega}. \quad (3.18)$$

El retardo de fase representa el retraso que experimentaría una señal sinusoidal de frecuencia ω al atravesar dicho sistema. Algunos autores definen la expresión (3.18) sin el signo menos. Por otro lado, el retraso de grupo de un sistema se define tal y como indica la expresión (3.19):

$$\tau_g(\omega) = \frac{-d}{d\omega} \theta(\omega). \quad (3.19)$$

Esto es, la tangente cambiada de signo en cada punto del diagrama de la respuesta de fase de tal sistema. Para sistemas con un retraso de grupo constante sobre todo el ancho de banda de una señal modulada, la envolvente de la misma será retrasada en un valor igual a τ_g . Si el retraso de grupo no es constante en todo el ancho de banda, entonces la envolvente estará

distorsionada.

Si una señal de entrada de la forma definida en (3.20) es aplicada a un sistema con una respuesta de fase lo suficientemente suave, la respuesta del mismo vendría dada por (3.21) donde la envolvente es modificada según el retardo de grupo, mientras que la portadora lo es por el retardo de fase.

$$x(t) = A_m(t) \cos(\omega t), \quad (3.20)$$

$$H[x(t)] = KA(t - \tau_g) \cos[\omega(t - \tau_f)], \quad (3.21)$$

donde K es la ganancia del sistema en el entorno de la frecuencia de la portadora. Para evitar la deformación de la señal, se hace necesario la construcción de filtros con un retardo de grupo constante en la banda de interés.

Un filtro ideal sería aquel que poseyera una forma rectangular en el espectro de la respuesta en magnitud. Este daría como resultado frecuencias de paso sin atenuación bloqueando por completo las frecuencias indeseadas. Desafortunadamente, un filtro ideal no es realizable debido a que no cumple el principio de causalidad.

3.2.1. Descripción de los filtros FIR.

En primer lugar hay que comentar que tanto los filtros IIR como los filtros FIR poseen ventajas y desventajas que hacen que ninguno de ellos sea mejor que el otro para cualquier situación. Los filtros FIR (*finite impulse response*) son usados casi de manera exclusiva en sistemas de tiempo discreto. A diferencia de los filtros IIR, los filtros FIR no precisan de transformaciones desde filtros analógicos ni algoritmos iterativos. Las técnicas de diseño de filtros FIR están basadas en aproximar directamente la respuesta en frecuencia del sistema lineal discreto [150].

Las principales ventajas de los filtros FIR son las siguientes:

- Los filtros FIR se pueden diseñar fácilmente para que tengan un retraso de fase constante y/o un retraso de grupo constante.
- Los filtros FIR implementados con técnicas no recursivas serán siempre estables y libres de oscilaciones de ciclo límite que pueden llegar a ser muy problemáticas en los filtros IIR.

- El ruido de redondeo (debido a la aritmética de precisión finita empleada por el procesador digital) puede hacerse relativamente pequeño en implementaciones no recursivas.

A pesar de ello, también tiene algunas desventajas como:

- La duración de la respuesta al impulso de un filtro FIR a pesar de ser finita, puede ser muy larga para obtener frecuencias de corte muy puntiagudas.
- Por lo general, el diseño de filtros FIR es más complejo que el de filtros IIR para reunir objetivos específicos de funcionamiento en aplicaciones similares.

La respuesta al impulso de un filtro FIR $h_d[n]$ está relacionada con la respuesta en frecuencia $H_d(e^{j\omega})$ mediante la transformada de Fourier haciendo uso del conocido método de la ventana:

$$H(e^{j\omega}) = \sum_{n=-\infty}^{\infty} h[n] \cdot e^{-j\omega n}, \quad (3.22)$$

$$H[n] = \frac{1}{2\pi} \int_{-\pi}^{\pi} H(e^{j\omega}) \cdot (e^{-j\omega n}) d\omega. \quad (3.23)$$

Dado que existen sistemas con respuestas en frecuencia a trozos constantes, propias de sistemas no causales y por tanto infinitamente largos, es necesario aproximar estos sistemas truncando su respuesta en frecuencia:

$$h[n] = h_d[n] \cdot w[n], \quad (3.24)$$

donde $w[n]$ es la función ventana rectangular:

$$w[n] = \begin{cases} 1 & 0 \leq n \leq M \\ 0 & \text{resto de casos} \end{cases} \quad (3.25)$$

Del teorema de modulación o ventaneo [150] se sabe que:

$$H_d(e^{j\omega}) = \frac{1}{2\pi} \int_{-\pi}^{\pi} H_d(e^{j\omega}) \cdot W(e^{j(\omega-\theta)}) d\theta. \quad (3.26)$$

Es decir, $H_d(e^{j\omega})$, la función de transferencia del filtro, es la convolución periódica de la respuesta ideal deseada con la transformada de Fourier de la ventana. La función ventana que de manera más fidedigna reproduzca la respuesta en frecuencia ideal será aquella lo más parecida a un impulso. Para el caso de la ventana rectangular se tiene que su transformada de Fourier es:

$$W(e^{j\omega}) = \sum_{n=0}^M e^{-j\omega n} = e^{-j\omega \frac{M}{2}} \frac{\sin[\omega \frac{(M+1)}{2}]}{\sin(\frac{\omega}{2})} \quad (3.27)$$

De (3.27) se puede observar que si M (orden o longitud del filtro) crece, el lóbulo principal se estrecha, incrementando las operaciones de cómputo. En cuanto a la respuesta en fase, una de las ventajas de los filtros FIR la constituye el hecho de que es posible obtener una respuesta lineal generalizada sin más que las ventanas cuenten con la propiedad:

$$w[n] = \begin{cases} w[M - n] & 0 \leq n \leq M \\ 0 & \text{resto de casos} \end{cases} \quad (3.28)$$

Existen varios tipos de ventanas como la Hann, Hamming y Blackman [80] que consiguen reducir la respuesta en magnitud de la banda de rechazo. No obstante, esto sólo es posible incrementando la amplitud del lóbulo principal y por tanto siendo la transición entre la zona de paso y la zona de rechazo más grande.

Aunque el método de la ventana es el más sencillo para diseñar filtros de este tipo, el algoritmo de Parks-McClellan da lugar a filtros de órdenes más bajos. Esto puede resultar importante para economizar recursos como la complejidad en hardware, área del chip, o velocidad computacional ya que éstos están relacionados de alguna manera con el orden del filtro [150].

3.2.2. Diseño de un filtro FIR de rizado uniforme óptimo.

En esta tesis, se usa el algoritmo de Parks-McClellan para el diseño de un filtro FIR óptimo de rizado uniforme. El algoritmo Parks-McClellan [152] es un algoritmo iterativo para encontrar el filtro FIR óptimo de Chebyshev. Este algoritmo se utiliza para diseñar e implementar filtros FIR eficientes y óptimos, usando un método indirecto para encontrar los coeficientes óptimos del filtro. Este algoritmo a su vez está basado en la filosofía del método de intercambio de Remez y en la teoría de aproximación de Chebyshev para diseñar filtros con un ajuste óptimo entre las respuestas de frecuencia deseadas y reales. Su objetivo es minimizar el error en las bandas de paso y de rechazo utilizando la aproximación de Chebyshev. Los filtros diseñados de esta manera presentan un comportamiento *equiripple* o de rizado uniforme en sus respuestas de frecuencia.

Considerando un filtro ideal de la forma (3.29) y su respuesta en frecuencia real modelada por (3.30):

$$H_d[e^{j\omega}] = \begin{cases} 1 & 0 \leq \omega \leq \omega_p \\ 0 & \omega_p \leq \omega \leq \pi \end{cases} \quad (3.29)$$

$$A_e(e^{j\omega}) = \sum_{k=0}^L a_k (\cos \omega)^k, \quad (3.30)$$

y teniendo en cuenta que su respuesta real en frecuencia, por ser un filtro FIR, puede escribirse como:

$$A_e(e^{j\omega}) = h_e[0] + \sum_{n=1}^L 2h_e[n] \cos(\omega n), \quad (3.31)$$

con

$$\cos(\omega n) = T_n \cos(\omega), \quad (3.32)$$

donde T_n es un polinomio de orden n , se tiene que la expresión del error queda:

$$E(\omega) = W(\omega) [H_d(e^{j\omega}) - A_e(e^{j\omega})], \quad (3.33)$$

donde $W(\omega)$ es una función de ponderación. Por lo tanto, el problema a minimizar se puede definir como:

$$h_e[n]: 0 \leq n \leq L \min \left(\omega \in [0, \pi] \max |E(\omega)| \right), \quad (3.34)$$

donde $h_e[n]$ son los coeficientes del filtro que minimizan el error máximo. Para resolver este problema se puede emplear la fórmula de interpolación de Lagrange a partir de unas frecuencias extremas predeterminadas para obtener los valores de $A_e(e^{j\omega})$. Posteriormente, se evalúan los $E(\omega)$ para un grupo de frecuencias en la banda de paso y de rechazo. Después, se comprueba que el error máximo cumple los criterios de diseño. En caso de no cumplir, se deben establecer de nuevo los valores de las frecuencias extremas.

El diagrama de flujo del algoritmo se puede ver en la Fig. 3.10, donde todos los valores de respuesta al impulso $h_e[n]$ son variados de forma implícita en cada iteración para obtener la aproximación óptima deseada. Una vez que el algoritmo converge, la respuesta al impulso puede ser computada con las muestras de la representación polinomial usando la transformada discreta de Fourier.

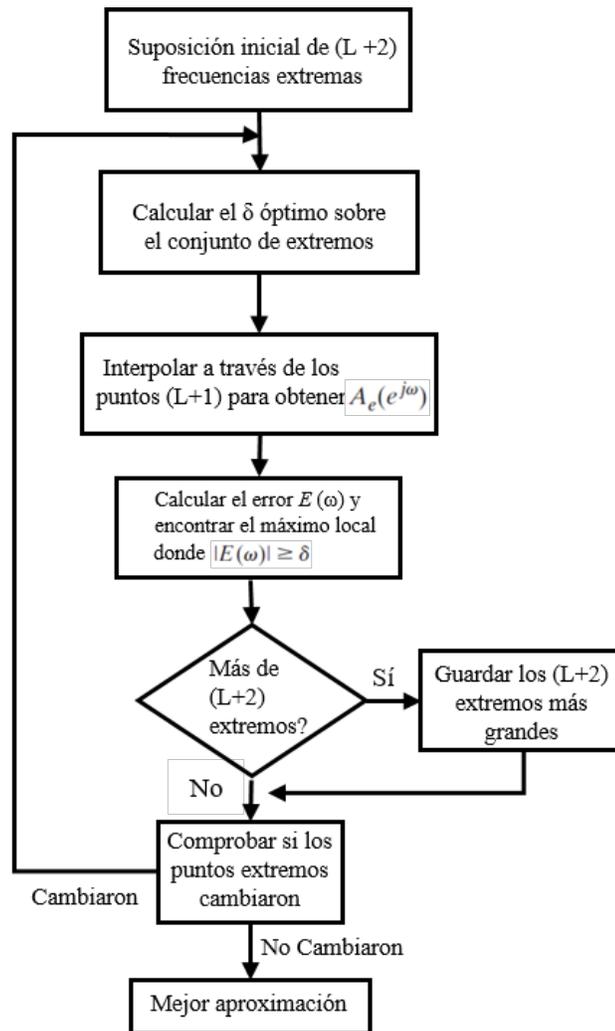


Figura 3.10: Diagrama de flujo del algoritmo Parks-McClellan [150].

3.2.3. Filtrado paso de banda de las frecuencias de interés.

Existen varias formas de implementar un filtrado de paso de banda [151]. Una es por medio de la combinación de un filtro de paso bajo y otro de paso alto para obtener un filtro de banda ancha. Otra es construir un filtro de banda estrecha, denominados normalmente así cuando el ancho de banda es inferior a una octava, los cuales pueden ser obtenidos a partir del modelo de filtro de paso bajo mediante la sustitución de la variable z en su FT por $[z - (\frac{1}{z})]$. La frecuencia de paso aparece centrada en la frecuencia de corte del filtro de paso bajo original. Sin embargo, esta última realización puede llegar a distorsionar las respuestas

transitorias [35].

3.3. Patrones característicos de asimetría rotórica.

El primer paso, como se ha visto en el capítulo 2, para elaborar una estrategia adecuada de monitorización de la condición de un MI, es escoger la magnitud que más información aporte sobre el fallo a diagnosticar. Además, será necesario en la medida de lo posible que esta magnitud no se vea alterada por factores que afecten o puedan dar lugar a falsos diagnósticos.

Los patrones característicos de asimetría rotórica se pueden obtener a partir de medidas estadísticas en el dominio del tiempo de la señal [22], y a través de amplitudes de frecuencias relacionadas con el fallo [44] o por medio de algunas relaciones basadas en las bandas laterales de armónicos en el espectro de la corriente [69, 153].

En muchos trabajos se emplean algunos de ellos de forma aislada y no se tiene en cuenta las variaciones en el poder discriminante de cada uno de ellos cuando son obtenidos para diferentes condiciones de operación (tipo de alimentación, nivel de carga, etc.). Es decir, en muchas ocasiones se obtienen los patrones de fallo para un conjunto de señales muy heterogéneo, lo que limita los resultados de las técnicas estadísticas o de aprendizaje automático empleadas en las metodologías propuestas en la literatura. A continuación, se presentan las características tomadas tanto de la onda temporal como del espectro en frecuencias que han sido usadas en esta tesis.

3.3.1. Patrones en el dominio del tiempo de la onda de corriente.

Varias características estadísticas tomadas directamente de la onda temporal, tanto de señales de vibración [22, 72, 98, 154] como de corriente [74, 107, 155] han sido usadas como indicadores de fallo en MI. Los estadísticos de orden superior [75] tienen la propiedad de ser sensibles a mediciones distribuidas de forma no gaussiana. Sin embargo, las estadísticas de orden inferior, aquellas que utilizan desde términos constantes a cuadráticos (por ejemplo, el primer y segundo momento), son significativamente más robustas [75].

En este apartado se presenta una recopilación de los indicadores más útiles para aplicarles directamente a la onda temporal, los cuales aportan información muy útil del estado del

motor. Estas características están constituidas por un conjunto de 18 indicadores estadísticos que van a ser utilizados inicialmente en la etapa de selección de características para el diagnóstico de barras rotas en MI.

1. *Máximo valor absoluto.*

$$x_p = \text{máx } |x| \quad (3.35)$$

2. *Valor de Pico.* El valor de pico de una señal $x[n]$ está definido como la mitad de la diferencia entre el valor máximo y mínimo:

$$V_{pico} = \frac{1}{2} (\text{máx}(x[n]) - \text{mín}(x[n])) \quad (3.36)$$

Este indicador no es un estadístico como tal, y por ello esta característica tiene poco poder discriminante cuando factores ajenos al estado del motor como ruido, datos espurios, etc. están presentes.

3. *Valor RMS.* El valor eficaz o RMS (Root Mean Square) es equivalente al conocido momento de segundo orden (varianza).

$$V_{RMS} = \sqrt{\frac{1}{N} \sum_{n=0}^{N-1} [x[n] - \bar{x}]^2} \quad (3.37)$$

donde N es el número de muestras de la señal y \bar{x} el valor medio. Este indicador da información de la energía de una señal.

4. *Factor de cresta.* El factor de cresta se define de la siguiente manera:

$$f_{cresta} = \frac{V_{pico}}{V_{RMS}} \quad (3.38)$$

El factor de cresta es informativo de la naturaleza impulsiva de la señal. Es decir, de la agudeza de los picos (impulsos, etc.) presentes en la misma.

5. *Factor de forma.* El factor de forma (*shape factor*) es la relación entre el valor eficaz y el valor medio. Como se puede inferir da idea de la forma de la onda.

$$f_{forma} = \frac{V_{RMS}}{|\bar{x}|} \quad (3.39)$$

6. *Valor cuadrático medio.*

$$x_r = \left(\frac{1}{N} \sum \sqrt{|x|} \right)^2 \quad (3.40)$$

7. *Promedio de valores absolutos.*

$$|\bar{x}| = \frac{1}{N} \sum \bar{x} \quad (3.41)$$

8. *Momento de primer orden (Esperanza).* En general, los momentos de orden r , m_r , son valores que caracterizan a la señal discreta. Los momentos son capaces de caracterizar una distribución de probabilidad y sirven para comparar dos o más distribuciones de probabilidad.

$$m_1 = \frac{1}{N} \sum x[n] \quad (3.42)$$

9. *Momento de segundo orden (Varianza).*

$$m_2 = \frac{1}{N} \sum (x[n] - \bar{x}[n])^2 \quad (3.43)$$

10. *Momento de tercer orden.*

$$m_3 = \frac{1}{N} \sum (x[n] - \bar{x}[n])^3 \quad (3.44)$$

11. *Momento de cuarto orden.*

$$m_4 = \frac{1}{N} \sum (x[n] - \bar{x}[n])^4 \quad (3.45)$$

12. *Momento de sexto orden normalizado.*

$$m_6 = \frac{1}{N \cdot m_2} \sum (x[n] - \bar{x}[n])^6 \quad (3.46)$$

13. *Cumulante de primer orden.*

$$c_1 = m_1 \quad (3.47)$$

14. *Cumulante de segundo orden.*

$$c_2 = m_2 - m_1^2 \quad (3.48)$$

15. *Cumulante de tercer orden.*

$$c_3 = m_3 - 3 \cdot m_1 m_2 + 2 \cdot m_1^3 \quad (3.49)$$

16. *Cumulante de cuarto orden.*

$$c_4 = m_4 + 3m_3 m_1 - 3 \cdot m_2^2 + 12 \cdot m_2 m_1^2 - 6 \cdot m_1^4 \quad (3.50)$$

17. *Curtosis.* La medida de curtosis estudia la proporción de la varianza que es explicada por la combinación de datos extremos de la muestra respecto a la media en contraposición con datos poco alejados de la misma. Mayor curtosis significa mayor concentración de datos muy cerca de la media de la distribución coexistiendo al mismo tiempo con una relativamente elevada frecuencia de datos muy alejados de la misma. Esto permite caracterizar la forma de la distribución de frecuencias con colas muy elevadas y con un centro muy apuntalado.

$$Curtosis = \frac{m_4}{(\sqrt{m_2})^4} \quad (3.51)$$

18. *Skewness o sesgo.* El sesgo puede entenderse como un coeficiente de asimetría donde dependiendo del signo que éste tome, la distribución tendría asimetría hacia la derecha (positivo) o hacia la izquierda (negativo). A medida que su valor se acerca a cero la distribución será más simétrica. Su expresión es la siguiente:

$$Skewness = \frac{m_3}{(\sqrt{m_2})^3} \quad (3.52)$$

3.3.2. Patrones en el dominio de la frecuencia.

Como se ha observado anteriormente, el espectro de frecuencias de la corriente de alimentación de un MI suministrado por inversor presenta mucho contenido armónico indeseable. A pesar de ello, la operación con inversor también puede presentar firmas de fallo adicionales

útiles para el diagnóstico. Particularmente, el fallo de rotura de barras en el rotor se manifiesta como una serie de bandas alrededor del armónico fundamental separadas simétricamente una distancia que depende del deslizamiento y por tanto de la carga conectada al motor. Este patrón también se repite alrededor de los armónicos temporales introducidos por el inversor añadiendo nuevos indicadores para el diagnóstico [8, 29, 120, 142, 156]. Sin embargo, el problema estriba en la detección temprana de fallos donde para ciertas condiciones, como pueden ser las de alimentación por inversor, la identificación de las frecuencias de fallo se complica por el ruido introducido por el inversor, entre otros factores.

A continuación, se detallan otros indicadores que han resultado útiles para cuantificar el fallo de barras rotas en MI alimentados por inversor.

3.3.2.1. Cuantificadores de la severidad del fallo.

Aunque no existen muchos estudios que analicen el problema de cuantificar la severidad de un fallo de barra rota, sí es cierto que algunos autores han investigado la influencia del inversor en el diagnóstico de fallos en MI. En [142] se presenta un trabajo donde se muestran los efectos en la detección de fallos de MI basados en MCSA cuando se alimentan con inversor. Se muestra de forma teórica y experimental que las firmas de fallo entre los armónicos del inversor y la generada por la componente fundamental de la corriente de línea son similares y comparables. En este trabajo se presentan relaciones matemáticas para fallos en rodamientos, excentricidad mixta y barras rotas. Los autores afirman que para barras rotas, la amplitud de los armónicos impares se ve incrementada. La amplitud de la primera banda lateral izquierda de los armónicos impares (estudio hecho para motores con 1 barra rota) resulta ser entorno a 5 dB más elevada que las del motor sano. Los autores en [157] proponen un criterio definido matemáticamente basado en el mecanismo electromagnético de las componentes laterales del armónico fundamental. Según los autores este criterio incluye la influencia de las corrientes entre barras asociadas a fallos de barra rota. Por otro lado, en [23] se hace un repaso a las técnicas de detección de fallos mecánicos en el rotor (excentricidad, rotura de barras y anillo de cortocircuito, arqueamiento del rotor y fallos originados por éstos) donde se puede encontrar una tabla de correlaciones para estimar el número de barras rotas en un MI. En [158] se presentan unos índices basados en coeficientes obtenidos con la transformada *wavelet* para diagnosticar fallos en el rotor por medio de la corriente de alimentación del motor. Estos índices permiten diagnosticar durante el transitorio de arranque para diferentes cargas. Los autores muestran los resultados para fallos de 1,2,3, y 4 barras rotas con cargas

del 33 %, 66 %, 100 % y 133 %. En [149], Wolbank *et al.* proponen un método para detectar defectos en la barra del rotor sin carga o casi parado.

Cambiando un poco la manera de plantear el diagnóstico, los autores en [159] hacen una caracterización rigurosa de la máquina bajo condiciones de estado de rotor sano. Su trabajo aporta reglas generales para relacionar el número de ranuras del estátor, barras del rotor y número de polos, así como la existencia de RSH y los armónicos relacionados con la saturación en el espectro de la corriente del estator.

Los autores en [69] proponen un método para cuantificar la detección de barras rotas para MI controlados en lazo cerrado. Debido a que el inversor tiene un efecto en las corrientes y en las tensiones se pueden tomar ambas magnitudes para evaluar la extensión del fallo ya que resulta casi independiente del modo de control.

Para motores alimentados por inversor donde se produce una regulación de velocidad variando la frecuencia se ha observado, sobretodo en motores empleados en sistemas de tracción, que el problema de barra rota es consecuencia de pares armónicos sextos producidos por la señal no senoidal [69]. En [69] se afirma que los indicadores basados en los armónicos laterales de la corriente, para la detección de barras rotas, presentan rechazo a variaciones en frecuencia así como al nivel de carga, la inercia y los parámetros del motor. Hay que recordar que los indicadores basados en la componente fundamental de la señal presentados en [44] dependen mucho de estas condiciones [44,69]. Sin embargo, los indicadores presentados en [69] muestran las siguientes ventajas:

- Aumentan la insensibilidad a perturbaciones tales como par de carga, inercia de accionamiento y variaciones de frecuencia.
- Presentan una baja dependencia respecto a los parámetros de la máquina (excepto al número de polos).
- Tienen una dependencia lineal con la gravedad del fallo.

Además pueden aplicarse directamente en motores alimentados por estrategias de control en bucle abierto.

El indicador clásico Γ_1 , el cual está relacionado con el LSH, se define como:

$$\Gamma_1 = \frac{I_{(1-2s)\omega}}{I_\omega}. \quad (3.53)$$

El resto de indicadores [69] usados en esta tesis han sido definidos de la siguiente manera:

$$\Gamma_5 = \frac{I_{(7-2s)\omega}}{I_{5\omega}}, \quad (3.54)$$

$$\Gamma_7 = \frac{I_{(5+2s)\omega}}{I_{7\omega}}, \quad (3.55)$$

$$\Gamma_{11} = \frac{I_{(13-2s)\omega}}{I_{11\omega}}, \quad (3.56)$$

$$\Gamma_{13} = \frac{I_{(11+2s)\omega}}{I_{13\omega}}, \quad (3.57)$$

donde los numeradores son la amplitud de las bandas laterales relacionadas con el fallo alrededor de los armónicos 5^o , 7^o , 11^o y 13^o , y los denominadores son las amplitudes de estos mismos armónicos. Las bandas laterales están separadas de los armónicos a una distancia en Hertz, que depende del deslizamiento del motor, s .

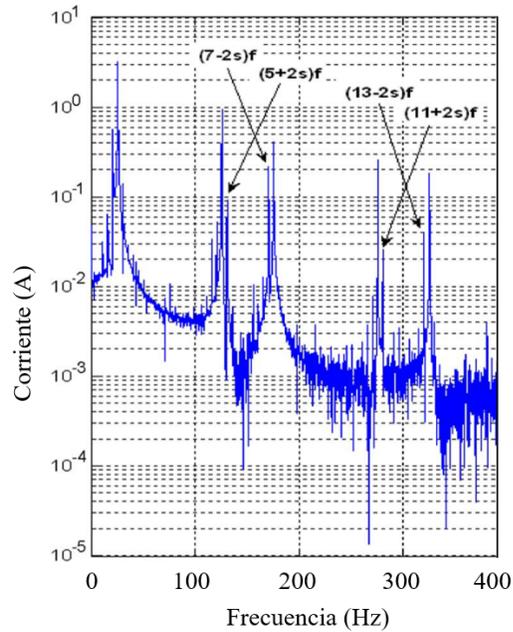


Figura 3.11: Espectro de la corriente de fase (frecuencia de alimentación de 25 Hz, seis barras rotas) [69].

En la Fig. 3.11 podemos observar la localización de los armónicos mencionados para definir los indicadores anteriores. Como se puede apreciar en [69], el indicador Γ_1 depende mucho de la carga del motor. Sin embargo, el resto de indicadores: Γ_5 , Γ_7 , Γ_{11} y Γ_{13} ; no dependen tanto de la carga del motor, mostrando una relación bastante lineal, siendo además más sensibles a la severidad del fallo del rotor.

A pesar de que existen varios trabajos que estudian cómo cuantificar barras rotas, los indicadores anteriores no han sido usados para el diagnóstico temprano de barra rota, entendiendo como temprano las severidades anteriores a la rotura completa de una barra.

3.4. Aspectos a tener en cuenta para el diagnóstico.

El conjunto de datos empleado para la calibración del clasificador toma un papel fundamental para construir una herramienta de diagnóstico con buenas prestaciones. Desde un punto de vista estadístico se requieren un número elevado de observaciones para poder desarrollar una herramienta de diagnóstico fiable. Sin embargo, esto no es posible en condiciones de operación reales en la industria cuando la máquina desarrolla un fallo temprano. Estas circunstancias, dan lugar a que los datos y patrones de fallo disponibles de la máquina bajo condiciones similares de operación sean estrictamente limitados. Por ello, es muy común que se disponga de mayor información de la máquina en estado sano que bajo situación de fallo. Estas circunstancias harán que usualmente los datos obtenidos de la máquina formen conjuntos de datos pequeños y desequilibrados, es decir, que los datos correspondientes a la clase de fallo sean muy reducidos en relación a los de la clase de motor sano.

Por otro lado, en cualquier actividad relacionada con la monitorización, el diagnóstico y los pronósticos, la precisión y la credibilidad de los resultados es de suma importancia. Dos tipos principales de errores de diagnóstico, llamados Tipo I y Tipo II o Falso Positivo (FP) y Falso Negativo (FN) respectivamente, se encuentran en muchas disciplinas. Se han discutido a fondo, especialmente en el campo de la medicina, donde las consecuencias de cometer un error de este tipo pueden ser particularmente graves. Dentro del ámbito industrial, la ocurrencia de errores en el diagnóstico de máquinas eléctricas rotativas también acarrea severas consecuencias. El objetivo de usar herramientas de diagnóstico orientadas al mantenimiento es el siguiente: reducir los costos aumentando la confiabilidad del sistema, aumentar la seguridad, disminuir el tiempo de inactividad, etc. Por ello, el valor de los resultados diagnósticos

está fuertemente influenciado por la precisión diagnóstica. Reducir el número de FP y FN puede marcar la diferencia entre un sistema de diagnóstico útil y otro inútil.

En este apartado examinamos diversos factores que influyen en la exactitud diagnóstica de los clasificadores binarios para evitar las consecuencias que puede tener una mala o incompleta evaluación de la herramienta de diagnóstico.

3.4.1. Evaluación del comportamiento del clasificador.

Se ha observado, durante el estudio del estado del arte de los sistemas de diagnóstico de fallos propuestos, que muchos de ellos carecen de una evaluación homogénea del clasificador. Los criterios de evaluación utilizados no permiten comparar los resultados de las prestaciones de la herramienta de diagnóstico.

La evaluación del clasificador en algunas publicaciones es muy limitada, basándose simplemente en la exactitud (*accuracy*) y en la tasa de error. Otros autores utilizan la matriz de confusión (MC) sin explorar las métricas que se pueden calcular a partir de ella. Además, aparte de las métricas, es aconsejable considerar la estimación del error para optimizar adecuadamente los parámetros de ajuste del clasificador. Incluso, es aconsejable aplicar pruebas de significancia estadística para probar que los resultados no hayan sido obtenidos por mero azar.

Por lo tanto, existe una necesidad y oportunidad de presentar las contribuciones más recientes de la literatura [129,130] sobre la evaluación del desempeño de clasificadores supervisados, que ayuden a diseñar procesos de evaluación más homogéneos y comparables.

El procedimiento de evaluación sigue básicamente tres pasos:

1. Medir la calidad de clasificación de cada clase para un objetivo particular (medidas de desempeño).
2. Estimar el comportamiento del clasificador con métodos de estimación de error según las características del conjunto de datos de partida.
3. Probar si el comportamiento del clasificador obtenido es estadísticamente significativo.

3.4.1.1. Métricas y curvas de evaluación.

La elección de las métricas o curvas de evaluación de las prestaciones del clasificador que se trata de diseñar debe tener en cuenta aspectos como el desequilibrio de clases o aportar información sobre cómo son clasificadas las observaciones pertenecientes a cada clase.

Real	Predicción		
	<i>Clase₁</i>	<i>Clase₂</i>	Total
<i>Clase₁</i>	Verdadero Positivo (TP)	Falso Negativo (FN)	P_{Real}
<i>Clase₂</i>	Falso Positivo (FP)	Verdadero Negativo (TN)	N_{Real}
Total	P_{Pred}	N_{Pred}	M

Tabla 3.1: Matriz de confusión.

En el campo de la AI, la MC es una herramienta muy usada para visualizar el desempeño de un algoritmo empleado para un aprendizaje supervisado. Cada columna de la matriz representa el número de predicciones de cada clase, mientras que cada fila representa a las observaciones correspondientes a la clase real. La principal virtud de la MC es la facilidad con la que permite observar si el sistema está confundiendo dos clases. Si los datos de entrada son desequilibrados, es decir, la proporción del número de muestras de cada clase es muy diferente, la tasa de error del clasificador no es representativa de lo bien que realiza la tarea el clasificador. Si por ejemplo hay 990 muestras de la *Clase₁* y sólo 10 de la *Clase₂*, el clasificador puede tener fácilmente un sesgo hacia la *Clase₁*. Si el clasificador clasifica todas las muestras como *Clase₁* su precisión será del 99%. Sin embargo, esto no significa que sea un buen clasificador, pues tuvo un 100% de error en la clasificación de las muestras de la *Clase₂*.

En la Tabla 3.1 se presenta la MC para un problema biclase. A partir de esta tabla, se pueden obtener métricas como:

1. *Accuracy o exactitud.* Una de las métricas más utilizadas para evaluar la clasificación discreta en el diagnóstico de máquinas eléctricas es la exactitud o *accuracy*. Esta métrica es indicativa del error de clasificación cometido evaluando dos o más clases:

$$Accuracy = \frac{TP + TN}{N} \quad (3.58)$$

Al clasificar varias clases, esta métrica es optimista ya que todos los errores de clasificación se consideran igualmente, y los errores de cada clase no son evaluados individualmente. Dos clasificadores podrían tener la misma exactitud pero pueden proporcionar una clasificación diferente para cada clase.

Las siguientes métricas aportan más información sobre las clases de la variable a predecir.

2. *Especificidad o True Negative Rate (TNR)*. TNR es una métrica de rendimiento enfocada en la clase negativa.

$$TNR = \frac{TN}{TN + FP} \quad (3.59)$$

3. *Precisión o Precision*. Por el contrario, esta métrica de rendimiento evalúa la clasificación correcta de la clase positiva.

$$Precision = \frac{TP}{TP + FP} \quad (3.60)$$

4. *Sensibilidad, True Positive Rate (TPR) o Recall*. Esta medida, junto con la especificidad, proporciona una proporción de muestras de una clase correctamente clasificadas. Sin embargo, al igual que *Precision*, sólo evalúa la clase positiva.

$$TPR (Recall) = \frac{TP}{TP + FN} \quad (3.61)$$

5. *Medida-F o F-measure*. Esta métrica puede ayudar a resolver cualquier contradicción que pueda aparecer entre las métricas *Precision* y *Recall*. Existen varias versiones, dependiendo del valor asignado a α , lo que permite elegir cómo ponderar a la *Precision* y *Recall*. Para $\alpha \in \mathfrak{R}, \alpha > 0$, la expresión general se muestra a continuación:

$$f_{\alpha} = \frac{(1 + \alpha)(Precision \times Recall)}{(\alpha \times Precision) + Recall} \quad (3.62)$$

6. *Media geométrica o Geometric mean*. Esta métrica proporciona información sobre el rendimiento del clasificador en un problema desequilibrado. Hay dos versiones de esta

métrica. $G_{mean,1}$ se utiliza para evaluar el equilibrio relativo del rendimiento del clasificador en todas las clases:

$$G_{mean,1} = \sqrt{TPR \times TNR} \quad (3.63)$$

La otra versión, $G_{mean,2}$, pone el foco en la clase positiva, tomando en cuenta la *Precision*.

$$G_{mean,2} = \sqrt{TPR \times Precision} \quad (3.64)$$

En ciertas situaciones, se requiere que los clasificadores asignen la pertenencia a una u otra clase usando un umbral. Para estos casos, es necesario incorporar alguna información adicional además de la deducida de la MC. Para ello, los métodos de análisis gráfico sirven como herramientas efectivas para describir el rendimiento de los algoritmos. Existen varios métodos gráficos para evaluar las prestaciones de los algoritmos de aprendizaje [129]. A continuación se presentan algunos de ellos.

7. *Curva ROC (Receiver Operating Characteristic)*. El análisis ROC se introdujo en la teoría de detección de señales y permite visualizar el rendimiento de un clasificador de forma gráfica. Esta curva (Fig. 3.12) ilustra el rendimiento de un clasificador binario según va variando su umbral de discriminación entre clases. La curva se crea trazando la tasa de TP frente a la tasa de FN variando el umbral. A diferencia de la Medida-F y la Precisión, esta métrica es insensible al desequilibrio de clases. El punto óptimo de operación se puede elegir de acuerdo a varias formulaciones [129, 160]. El área bajo la curva ROC es un escalar que nos da información útil del comportamiento de un clasificador [160]. Sin embargo, este escalar no sirve para comparar clasificadores cuando sus curvas ROC se cortan [130].

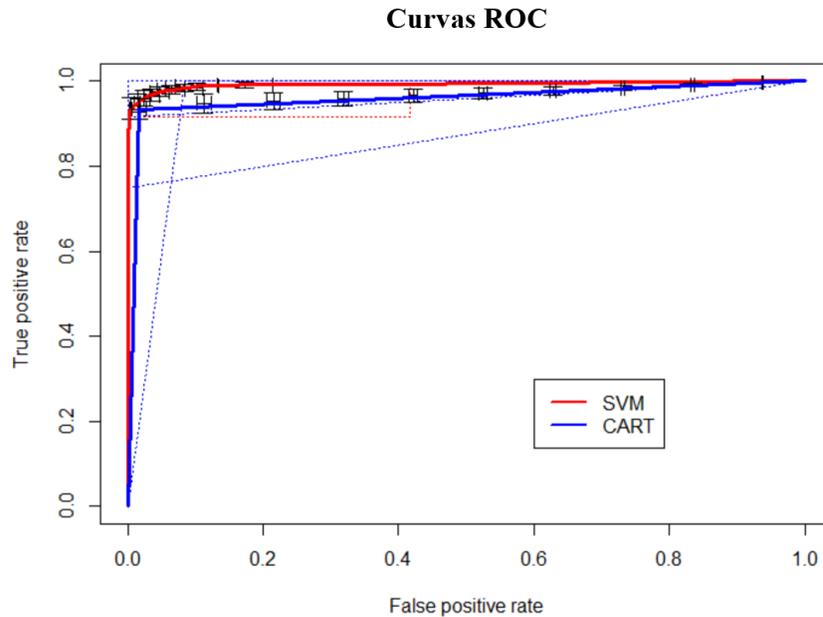


Figura 3.12: Ejemplo de curva ROC para dos clasificadores [161].

8. *Curva Precision-Recall*. Este tipo de gráfico (Fig.3.13) sirve para analizar el equilibrio entre los ejemplos positivos correctamente clasificados y los ejemplos negativos mal clasificados. Básicamente, es una gráfica donde el valor *Precision* del clasificador está representado como una función de los valores *Recall*. En otras palabras, en un escenario de diagnóstico de fallos, estas curvas representan la proporción de casos de fallos verdaderamente detectados referida a aquellos que se identifican como sanos (eje vertical) y en el eje x referido con respecto a la tasa de ocurrencia de falsas indicaciones positivas. Estas curvas han demostrado ser también útiles cuando se tiene el problema del desequilibrio de clases.

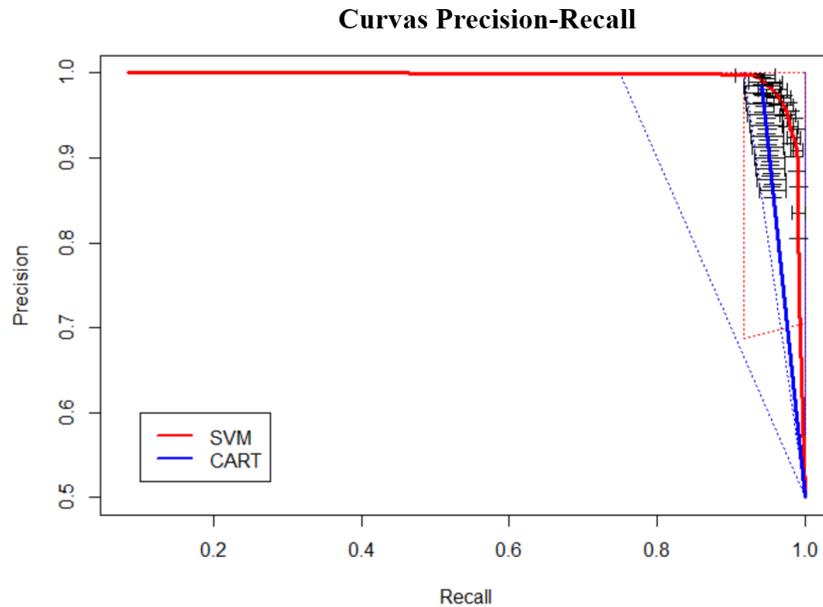


Figura 3.13: Ejemplo de curva Precision-Recall para dos clasificadores [161].

9. *Otros gráficos.* Las curvas de costes usan los costos de clasificación errónea (en caso de que se conozcan) en lugar de emplear las métricas de la curva ROC. La principal ventaja es su uso sencillo al decidir el clasificador más adecuado en aquellos casos en los que se conoce el coste de error, la distribución de clase o la proporción desequilibrada de las clases. La diferencia con las curvas ROC es que proporcionan información más práctica para aquellas circunstancias en las que la información requerida está disponible. Es decir, cuando el operador tiene suficiente conocimiento o información de los costes de parada inesperada, intervención innecesaria, etc.

Existen otros gráficos conocidos como *Lift Chart* que permiten visualizar los verdaderos positivos, pero en este caso contra el tamaño del conjunto de datos utilizado para lograr dicho número de verdaderos positivos. Para este gráfico, los verdaderos positivos se trazan en el eje vertical mientras que el eje horizontal indica el número de observaciones en el conjunto de datos tomado en cuenta los verdaderos positivos obtenidos en el eje vertical.

3.4.1.2. Métodos de estimación del error.

Un paso importante para construir un buen modelo predictivo es la elección de un método de estimación del error apropiado. Cada uno de estos métodos tiene un diferente comportamiento en términos de sesgo y varianza [130]. Es importante escoger aquel método más apropiado acorde al tamaño del conjunto de datos disponible. Muchos métodos de estimación del error se discuten en [129, 130, 162] y se pueden clasificar en las siguientes categorías: *Resubstitution*, *Holdout*, y *Resampling*.

Particularmente, en el caso de diagnóstico de fallos en MI, los datos de entrada provienen frecuentemente de MCSA o del análisis de la señal de vibración. Los datos disponibles son limitados y generalmente se usan en su totalidad para entrenar al clasificador. Es necesario construir un gran conjunto de datos de muestras, suficiente para la etapa de prueba, para hacer el mejor uso de los datos adquiridos. Esto se consigue fácilmente mediante métodos de remuestreo. Básicamente, hay dos tipos de métodos: re-muestreo simple y remuestreo múltiple. En este último, se incluyen los siguientes métodos: Sub-muestreo aleatorio, *Bootstrapping*, *Randomization* y repetición en *k-folds* de validación cruzada. La ventaja de los métodos de remuestreo múltiple sobre el remuestreo simple es la estabilidad en las estimaciones. Este hecho resulta en un gran número de muestras, pero esto puede conducir a violar la suposición de independencia entre el conjunto de datos de prueba y los conjuntos de datos de entrenamiento. El método de Resubstitución obtiene estimaciones muy optimistas ya que se usan los mismos datos en las etapas de entrenamiento y prueba. Debido a este sesgo, el uso de este método con muestras de datos pequeños proporciona malos resultados. El método *Holdout* es una alternativa a *Resubstitution*, donde el conjunto de datos se divide en dos grupos exclusivos, uno para entrenamiento y el otro para prueba. El primero es generalmente más grande. Este método proporciona una estimación pesimista y sesgada del error de clasificación. A medida que aumenta el número de muestras en el conjunto de datos, este sesgo disminuye pero, por otra parte, la varianza de la estimación del error aumenta. En el método de validación cruzada (VC) repetida *k-folds*, el conjunto de datos se divide en *k-folds* de igual tamaño y mutuamente excluyentes. Todos excepto un *fold* se usan para entrenamiento y el restante para prueba. Como sugiere el nombre de este método, este procedimiento se repite tantas veces como el evaluador lo considere. El error de clasificación se obtiene promediando cada error *k* en cada repetición. En el método CV de *k-fold*, cuando el número de *folds* es el mismo al tamaño del conjunto de observaciones, el método se llama *Leave-one-out*. Este método tiene un costo computacional más alto, lo que le hace poco práctico para algunas aplicaciones. El método conocido como *Bootstrap* [114] puede ser una mejor opción que la

validación cruzada *k-fold* en aquellos casos en los que el conjunto de datos sea relativamente pequeño. Hay varias variantes de *Bootstrap* utilizadas en estadística. El *Zero-Bootstrap* es una variante mejorada del *Bootstrap* simple, que sufre de sobreajuste [129]. Básicamente, consiste en muestrear uniformemente con reemplazo m instancias del conjunto de datos, denotado por S . La probabilidad de que cada instancia sea elegida es $\frac{1}{m}$ y la probabilidad de no ser elegida es $\left(1 - \frac{1}{m}\right)$. Para cualquier observación dada, la probabilidad de no ser elegido después de m muestras, cuando m es grande, es:

$$\left(1 - \frac{1}{m}\right)^m \cong \frac{1}{e} \cong 0.368 \quad (3.65)$$

Por lo tanto, el número esperado de diferentes instancias en la muestra resultante de m observaciones es $(1 - 0.368) \cdot m = 0.632 \cdot m$. Por lo tanto, el conjunto de prueba, T_{boot} está formado por todas las observaciones de S no presentes en S_{boot} . Un clasificador f_{boot} se obtiene con S_{boot} y se prueba con T_{boot} . El riesgo empírico estimado de f_{boot} se obtiene sobre T_{boot} . Este procedimiento se repite k veces y se promedia el respectivo riesgo empírico para obtener el estimador $boot.0_e$ que puede resultar pesimista ya que el clasificador se entrena típicamente usando sólo el 63.2% del conjunto de datos en cada paso. Como consecuencia, el 0.632 *Bootstrap* [114] trata de corregir el sesgo pesimista teniendo en cuenta el sesgo optimista del error de resubstitución sobre la fracción restante 0.368:

$$boot.0.632_e = \frac{1}{k} \sum_{i=1}^k 0.632 \cdot boot.0_{e,i} + 0.368 \cdot err_e(C), \quad (3.66)$$

donde $err_e(C)$ representa el error de resubstitución del clasificador C obtenido con el conjunto de entrenamiento, S . Esta última variante puede conducir a estimaciones con menor varianza como resultado del aumento del tamaño del conjunto de datos. Una mejora a este método de validación cruzada es el 0.632 *plus Bootstrap* (ó 0.632 + *Bootstrap*) [163], que corrige el sesgo cuando hay una gran cantidad de sobreajuste. De hecho, los pesos se asignan individualmente para cada modelo para revelar la bondad en la creación de la muestra de entrenamiento. Esta versión considera el error para los casos en los que las variables dependientes e independientes no fueron asociadas. Generalmente, el número de repeticiones o *bootstraps* para conseguir una buena estimación es mayor que para el caso de VC con *k-fold*, siendo valores usuales $k \geq 200$ [129].

3.4.1.3. Pruebas de significancia estadística.

Las pruebas de significancia estadística ayudan al investigador a ser más preciso para verificar el grado de aleatoriedad de los resultados obtenidos. Este paso puede ayudar a controlar la probabilidad de errar al declarar un modelo mejor que otros. Para estos propósitos, varias pruebas estadísticas se han discutido de acuerdo a una amplia variedad de escenarios en el área del aprendizaje automático [129]. Las pruebas estadísticas más usadas para comparar resultados de varios clasificadores para un sólo conjunto de datos son el “*Two-matched samples t-test*” y el “*McNemars test*”. La prueba-t es paramétrica y debe cumplir las hipótesis de normalidad, aleatoriedad de las muestras e igualdad de varianzas. En el caso de que estas hipótesis no se cumplan, es aconsejable usar el test no paramétrico de McNemar [129, 161].

3.5. Conclusiones del capítulo.

En este capítulo, se introdujo la problemática que crean los inversores en el diagnóstico de motores inducción. Posteriormente, se describió el filtrado FIR, técnica usada en una de las etapas de una de las metodologías propuestas para la localización y cuantificación del fallo de barra rota. Después, se presentaron los patrones o características que van a ser procesados y por tanto, utilizados para el modelado y validación de la herramienta de diagnóstico. Finalmente se introdujeron los aspectos a tener en cuenta para el desarrollo de un procedimiento de evaluación para el escenario en el que se desea construir el clasificador usado para diagnóstico.

Las métricas de rendimiento permiten comprender mejor cómo es predicha cada una de las clases en relación a los errores tipo I y tipo II. Los métodos de estimación del error dan información sobre la estabilidad de los resultados según cómo estén compuestos los conjuntos de entrenamiento y prueba. Finalmente, con las pruebas de hipótesis se tratará de corroborar que los resultados obtenidos no se deben al azar.

HH

Capítulo 4

Metodología.

En este capítulo se articulan las propuestas metodológicas diseñadas para crear una herramienta de diagnóstico orientada a identificar fallos incipientes en MI alimentados por inversor.

El objetivo principal es conformar una metodología de diagnóstico automático que presente buenas prestaciones ante conjuntos de datos pequeños y desequilibrados formados a partir de patrones obtenidos tanto de señales ruidosas, como lo son las obtenidas en condiciones de alimentación por inversor, así como para el caso de alimentación de red. No obstante, para obtener e identificar los patrones de fallo de las bandas laterales del armónico fundamental, se plantea otra propuesta metodológica con el objetivo de localizar las frecuencias de fallo incipiente en MI alimentados por inversor.

Para facilitar la organización de las contribuciones de cada propuesta metodológica, en la Fig. 4.1 se presenta un diagrama de bloques donde se representa gráficamente el orden de aparición de cada una de ellas para el adecuado entendimiento de la herramienta de diagnóstico.

En primer lugar, se plantea una metodología para procesar algunas características espectrales haciendo un procesamiento combinado con MUSIC y con la FFT, orientado a localizar las frecuencias de fallo y a cuantificar sus amplitudes, respectivamente. En segundo lugar se plantea un esquema para la selección de características antes de la etapa de clasificación. En este apartado se propone un método tipo envoltorio basado en la eliminación recursiva de características por medio del algoritmo *Random Forest*.

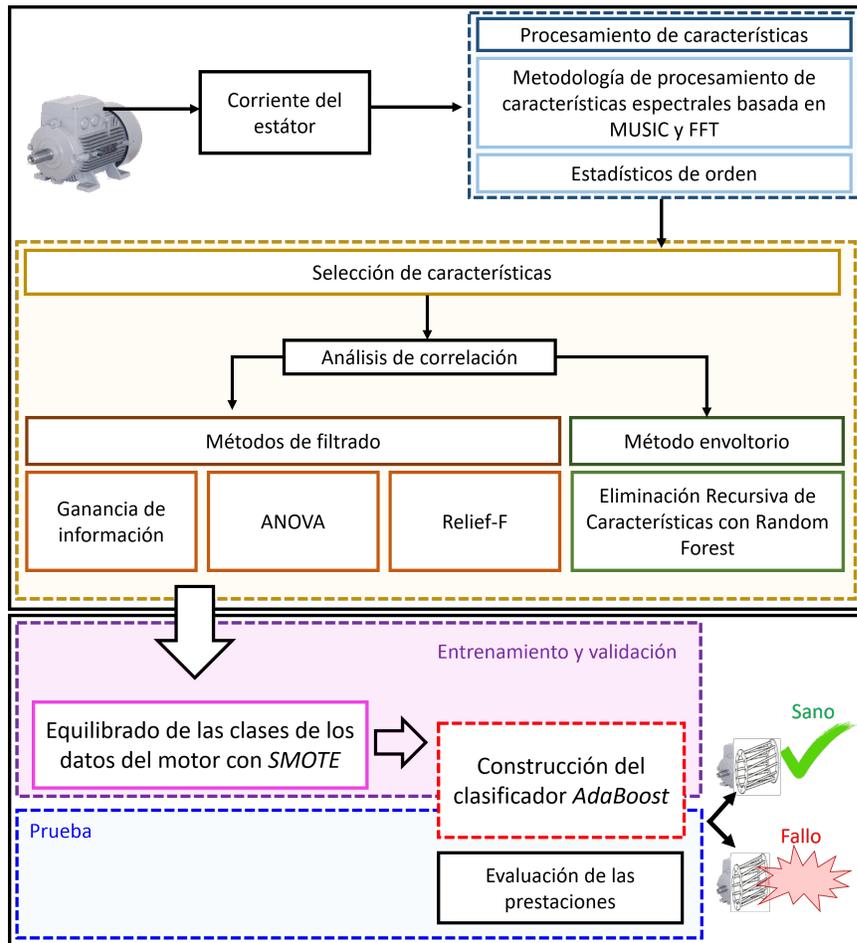


Figura 4.1: Diagrama de bloques donde se presenta el orden de aparición de las metodologías propuestas.

Esta técnica es comparada con algunos métodos tipo filtro como el criterio de Ganancia de Información, ANOVA y el algoritmo *Relief-F*. Finalmente, las técnicas empleadas en el bloque inferior de la Fig. 4.1 permiten construir una herramienta de diagnóstico aplicable a conjuntos de datos desequilibrados a través de un algoritmo de *Boosting* con un conjunto reducido de parámetros de ajuste partiendo de conjuntos de datos pequeños. Además, su aplicación en conjuntos de datos pequeños en aprendizaje supervisado supone un enfoque determinante debido al coste adicional de etiquetado que tienen los métodos supervisados.

4.1. Variables de seguimiento de la condición en régimen estacionario.

Teniendo en cuenta los sensores a emplear, las características creadas (descritas en 3.3) se pueden asignar a alguno de los siguientes tres grupos:

1. *Variables operativas del motor.* Las variables o características que forman parte de este conjunto son: velocidad, deslizamiento, nivel de carga, tipo de alimentación y valor eficaz de la corriente consumida por el motor.
2. *Variables del espectro de frecuencias.* Para la creación de estas características se han tenido en cuenta dos técnicas de análisis espectral:
 - características obtenidas con la transformada MUSIC (estimación de la frecuencia de fallo).
 - características obtenidas con la FFT (cuantificación de la severidad del fallo). Dentro de este grupo se encuentran: las amplitudes de LSH y RSH, y los ratios Γ_5 , Γ_7 , Γ_{11} y Γ_{13} introducidos en el apartado 3.3.2.1.
3. *Características o indicadores en el dominio del tiempo.* Dentro de este grupo se han tenido en cuenta varios indicadores descritos en el apartado 3.3.1

Las características relacionadas con las amplitudes de los armónicos de fallo han sido obtenidas con la Transformada de Fourier, concretamente con la FFT. Para ello se ha obtenido la densidad de potencia espectral (DPE) o como es conocida en inglés *Power Spectral Density* (PSD) normalizada a la componente fundamental de energía. En la tabla 4.1 se muestran las características espectrales usadas.

Denominación	Símbolo	Expresión
Banda lateral izq. del primer armónico	LSH	$f_{LSH} = (1 - 2s)f_1$
Banda lateral dcha. del primer armónico	RSH	$f_{RSH} = (1 + 2s)f_1$
Ratio alrededor del 5 ^o armónico	Γ_5	$\Gamma_5 = \frac{I_{(7-2s)\omega}}{I_{5\omega}}$
Ratio alrededor del 7 ^o armónico	Γ_7	$\Gamma_7 = \frac{I_{(5+2s)\omega}}{I_{7\omega}}$
Ratio alrededor del 11 ^o armónico	Γ_{11}	$\Gamma_{11} = \frac{I_{(13-2s)\omega}}{I_{11\omega}}$
Ratio alrededor del 13 ^o armónico	Γ_{13}	$\Gamma_{13} = \frac{I_{(11+2s)\omega}}{I_{13\omega}}$

Tabla 4.1: Características espectrales obtenidas de la corriente estatórica con la FFT.

4.2. Metodología de análisis espectral de alta resolución para la detección de fallo incipiente.

Como se puede inferir de lo descrito en el Capítulo 2, las técnicas de análisis espectral de alta resolución pueden ser muy útiles para la identificación de las frecuencias de fallo cuando la señal de análisis presenta un alto contenido tanto armónico como de ruido. Esto es así porque en motores alimentados por inversor el ruido introducido por éste en la señal estatórica complica la correcta localización de las frecuencias de fallo a través de la FFT. En la práctica, la FFT presenta muchos problemas ya que requiere de grandes periodos de adquisición de la señal y es muy difícil tener una señal completamente estacionaria. Además, bajo condiciones de alimentación por inversor en el espectro obtenido con la FFT aparece un alto nivel de ruido que complica la identificación del fallo incipiente. Sin embargo, el algoritmo MUSIC puede ser usado con señales adquiridas en un periodo de adquisición mucho más corto, lo que a su vez requiere menor necesidad de memoria para localizar las frecuencias de fallo de barra rota. Además, esto permite que se puedan aplicar técnicas de diezmado en la banda de interés reduciendo de manera significativa la tasa de muestreo y por tanto empleando un menor tiempo de computación. Uno de los mayores inconvenientes que tiene MUSIC es que requiere una elección adecuada de sus parámetros lo que hace que, si no se tienen en cuenta los resultados obtenidos con cada uno de ellos, la aplicación de la transformada arroje resultados erróneos entre señales de diferentes estados de severidad de fallo del motor. Ciertamente que en la literatura se han presentado trabajos que emplean MUSIC para la detección de

barras rotas en el rotor [17, 18, 87]. Sin embargo, su uso está limitado a motores alimentados directamente de la red o a fallos desarrollados como el caso de una o más barras rotas.

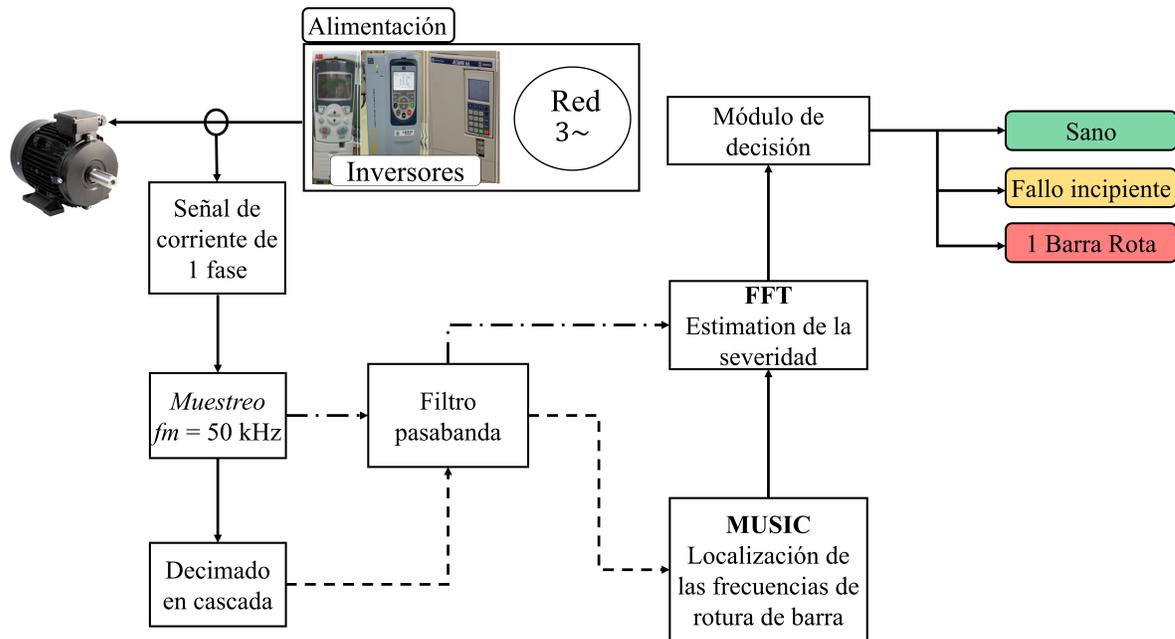


Figura 4.2: Diagrama de bloques de la metodología propuesta para la extracción de características espectrales alrededor de la frecuencia fundamental [164].

La primera metodología propuesta consiste en un sistema fuera de línea, donde los parámetros del algoritmo MUSIC son ajustados a partir de un conjunto significativo de señales bajo diferentes condiciones de operación y de severidad del fallo. El diagrama de esta propuesta puede verse en la Fig. 4.2. La metodología está conformada por los siguientes pasos:

1. Adquisición de una fase de la corriente estática bajo diferentes condiciones de alimentación (varios inversores y red) y carga.
2. Filtrado pasobanda a través de un filtro FIR usando el método de optimización de Parks-McClellan. Esta etapa permite observar mejor las frecuencias de fallo permitiendo eliminar las frecuencias provocadas por la intervención de los interruptores de los inversores en la zona de los kHz.

3. Fase de localización de frecuencias. En esta fase se ajustan los parámetros de MUSIC para cada tipo de alimentación y nivel de carga. Se escogen tres órdenes para tener mayor capacidad discriminativa entre el caso de motor sano y con fallo.
4. Fase de cuantificación del fallo. Tras verificar la presencia en frecuencia de componentes de fallo en el espectro con un intervalo reducido de muestras, lo que se hace en esta etapa es cuantificar de manera más precisa (con un mayor intervalo de tiempo para tener mayor resolución) la severidad de la rotura de la barra del rotor a través de la FFT.

La metodología incluye la localización precisa de las frecuencias de barra rota, que se realiza con MUSIC en un segmento de tiempo de un segundo. Este segmento de tiempo se ha escogido como se detalla a continuación. Inicialmente, se va aumentando el intervalo de tiempo de 0.1 s, hacia arriba en incrementos de 0.1 s. Se ha observado que cuando el intervalo de tiempo es 0.5 s o inferior, los espectros obtenidos no permiten localizar claramente los componentes de las frecuencias de fallo. En la Fig. 4.4 (a) se representa el caso de un segmento de 0.5 s de un MI alimentado por inversor ABB con carga alta. Cuando el intervalo de tiempo se incrementa a 0.6 s, los resultados muestran una buena localización de las componentes de frecuencia (Fig. 4.4 (b)), lo cual establece el límite inferior del intervalo de tiempo para tener una detectabilidad adecuada con MUSIC. Sin embargo, para tener un margen de seguridad en la localización del fallo, se elige un intervalo de tiempo de 1 s.

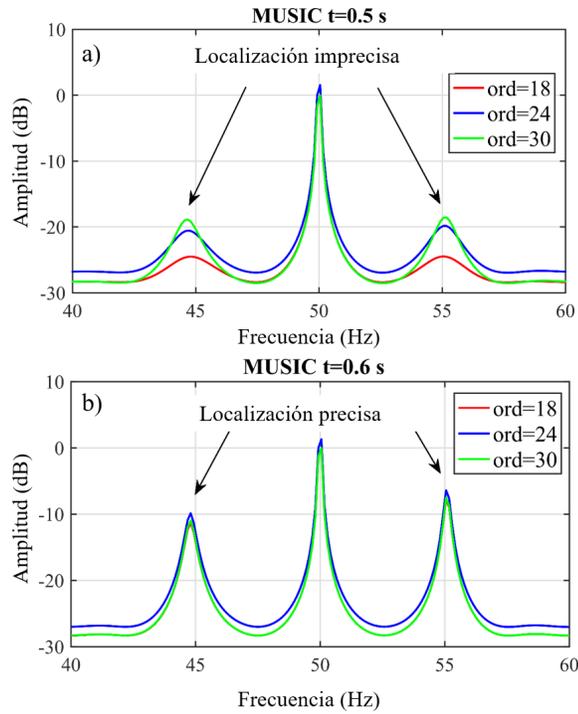


Figura 4.3: Influencia de los tiempos de adquisición para la detección del fallo de barra para la localización de la frecuencia. Inversor ABB con carga alta

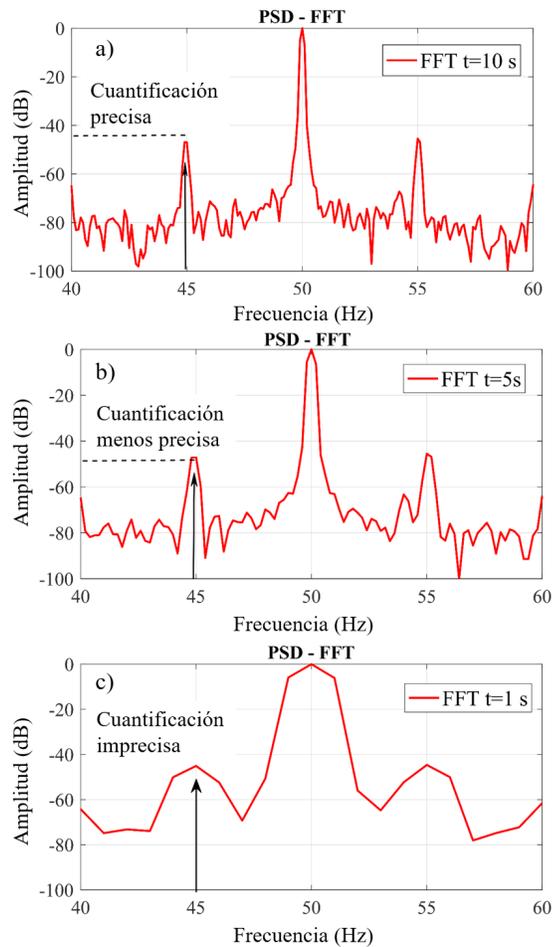


Figura 4.4: Influencia de los tiempos de adquisición para la detección del fallo de barra para la cuantificación de la severidad. Inversor ABB con carga alta.

En segundo lugar, la metodología requiere cuantificar la magnitud de las frecuencias de fallo, lo cual se realiza con la FFT en un segmento de tiempo de diez segundos. Esto se calcula aumentando el intervalo de tiempo de 1 s hacia arriba en incrementos de 1 s, aumentando la resolución en frecuencia. Cuando el intervalo de tiempo se incrementa a 10 s, los resultados muestran que la cuantificación de frecuencia puede ser estimada con precisión como se muestra en la Fig. 4.4 (a). Por lo tanto, con este intervalo de 10 segundos y una frecuencia de muestreo de 50 kHz, se consigue una resolución de frecuencia de 0.1 Hz. Para segmentos de tiempo más cortos, la resolución del método es pobre, y no permite llevar a cabo una buena cuantificación como puede verse en las Fig. 4.4 (b-c). Se puede observar que cuando el

intervalo de tiempo es de 5 s o inferior, el espectro obtenido muestra una resolución menor siendo incapaz de cuantificar claramente los componentes de frecuencia de barra rota.

Como resultado del análisis anterior, la longitud de la señal se reduce a 5000 muestras con un ancho de banda de 250 Hz que incluye las frecuencias de interés. Después de la etapa de adquisición de datos, la DPE de la señal se calcula usando el algoritmo FFT con una ventana Hann para reducir el efecto de fuga espectral. Para la estimación de la FFT, la longitud de las muestras de la ventana se establece en 4096 puntos. En ambos casos, el espectro FFT y el pseudo-espectro MUSIC se normalizan y se expresan en dB con respecto a la componente fundamental. El diagrama de flujo de los pasos realizados durante la etapa de análisis se detalla en la Fig. 4.5. Para realizar una elección adecuada de los parámetros de MUSIC con la metodología propuesta, ésta debe aplicarse a un conjunto de señales estadísticamente significativo [165]. Las señales usadas se describen en el capítulo 5.

Los parámetros de ajuste de MUSIC se eligen mediante un bucle iterativo que calcula un índice de fallo (IF) en el intervalo de las frecuencias correspondientes a las de fallo (véase la Fig. 4.5). El IF se define para los armónicos LSH y RSH como sigue:

$$IF_{LSH} = A_{f,LSH}^M - \min\{A_{f,LSH}^M, A_{f,1}^M\}, \quad (4.1)$$

$$IF_{RSH} = A_{f,RSH}^M - \min\{A_{f,1}^M, A_{f,RSH}^M\} \quad (4.2)$$

Ambos IF se calculan a partir del espectro MUSIC como la diferencia entre los valores de amplitud de pico en cada frecuencia característica, $A_{f,LSH}^M$ y $A_{f,RSH}^M$, y el valor mínimo (valor valle) encontrado entre ese pico y la componente fundamental $A_{f,1}^M$. Conociendo el deslizamiento, las frecuencias de barra rota pueden localizarse realizando una búsqueda de picos a través de la densidad espectral de potencia de la corriente del estátor alrededor de la componente fundamental (banda de frecuencia de interés). El esfuerzo computacional se usa principalmente en el análisis para cada valor m (orden de MUSIC) dentro del bucle, que considera el conjunto completo de señales experimentales. Este análisis iterativo permite elegir los órdenes MUSIC más apropiados para la localización del fallo incipiente en el rotor.

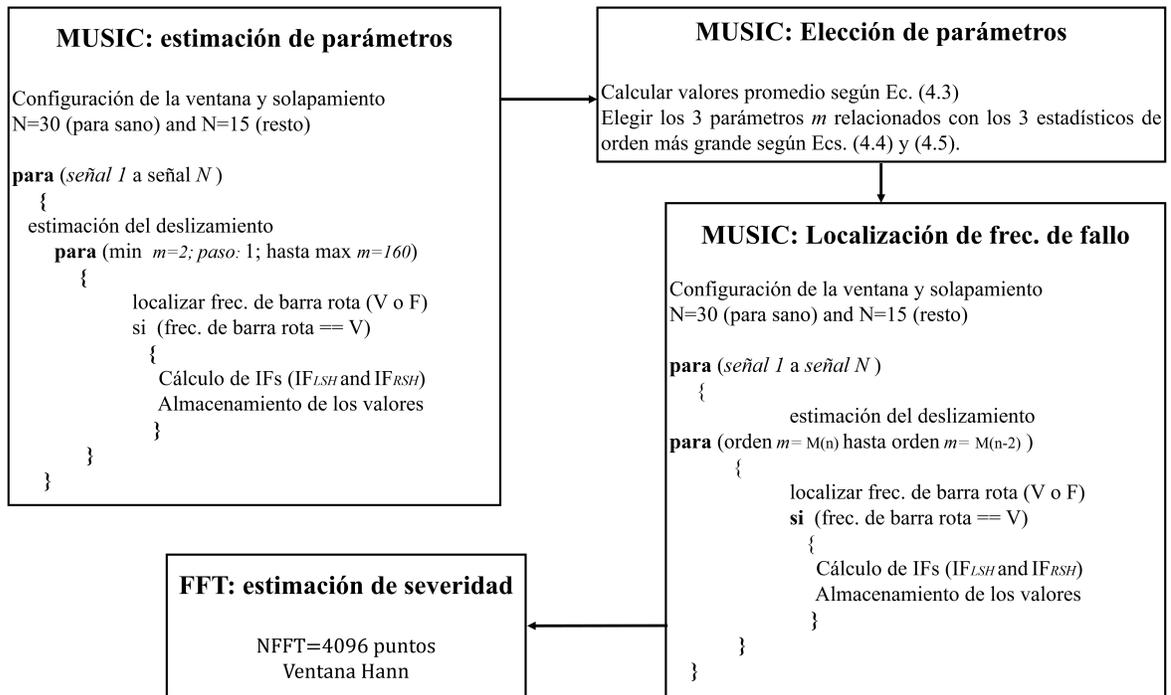


Figura 4.5: Diagrama de flujo con los pasos del procedimiento para el análisis de la severidad del rotor [164].

Dentro del bucle iterativo, la información de fallo se realiza primero buscando los picos de interés, frecuencias f_{LSH} y f_{RSH} en el pseudo-espectro MUSIC y luego, calculando los IF anteriores en caso de que los picos anteriormente mencionados aparezcan en los espectros. La información de la señal de fallo calculada durante este procesamiento se almacena en una matriz de datos. Debido a la naturaleza estocástica de la señal, se ha comprobado que no existe un orden único para obtener información relacionada con el fallo temprano para cada señal de todas las pruebas del conjunto de datos. Por esta razón, se eligen tres órdenes de MUSIC que presenten un mejor comportamiento discriminante entre los estados del rotor. Los órdenes se eligen de la siguiente manera:

1. Primeramente, se obtiene el promedio de los IF (4.4), calculado como (4.1) y (4.2) para el LSH y RSH respectivamente, para cada estado del rotor (R), señal y orden de MUSIC

analizado (m) en cada iteración (Fig. 4.5).

$$\bar{I}F_{m,R} = \frac{1}{N_t} \sum_{i=0}^{N_t} IF_{i,R} \quad m = 2, 3, \dots, 160 \quad (4.3)$$

donde N_t es el número de ensayos para cada estado del rotor. El mínimo ($m = 2$) y el valor máximo ($m = 160$) de m son elegidos en base al trabajo publicado en [166].

2. A continuación, se calcula la diferencia entre los valores calculados como (4.4) para los diferentes estados de rotora de la barra del motor.

$$\Delta \bar{I}F_{m,incip} = \bar{I}F_{m,R_{sano}} - \bar{I}F_{m,R_{fallo,i}} \quad m = 2, 3, \dots, 160 \quad (4.4)$$

3. Finalmente, estos valores se ordenan siguiendo el orden univariado de los datos estudiado en [167]. Sean los $\Delta \bar{I}F_{m,incip}$, dispuestos en orden ascendente de magnitud como:

$$\Delta \bar{I}F_{incip(1)} \leq \Delta \bar{I}F_{incip(2)} \leq \dots \leq \Delta \bar{I}F_{incip(n-2)} \leq \Delta \bar{I}F_{incip(n-1)} \leq \Delta \bar{I}F_{incip(n)} \quad (4.5)$$

El i -ésimo $\Delta \bar{I}F_{incip(i)}$ es el denominado estadístico de orden i , donde el mínimo es $\Delta \bar{I}F_{incip(1)}$, y el máximo es $\Delta \bar{I}F_{incip(n)}$. Los órdenes de MUSIC seleccionados son aquellos que corresponden con los siguientes estadísticos de orden: $\Delta \bar{I}F_{incip(n-2)}$, $\Delta \bar{I}F_{incip(n-1)}$, $\Delta \bar{I}F_{incip(n)}$.

4.3. Métodos de selección de variables y características.

Una vez que se dispone de patrones o características que puedan dar información adicional del estado del motor bajo alimentación por inversor, el siguiente problema es seleccionar el conjunto óptimo de las características de partida para obtener las mejores prestaciones del clasificador. La selección de características puede llegar a ser preferible a la transformación de características para aquellos casos donde el interés sea mantener el significado de las características originales así como identificar y modelar con el subconjunto más relevante.

Hay que entender que el problema fundamental que trata de resolver el aprendizaje automático es aproximar una función relacional $f()$ entre una entrada (vector de características) $X = \{x_1, x_2, \dots, x_M\}$ y una salida (variable respuesta) Y , basada en un conjunto de ejemplos u observaciones (ensayos) disponibles $\{X_i, Y_i\}, i = 1, \dots, N$. Normalmente, los vectores X_i

son números reales al igual que la codificación de la variable respuesta (estado del rotor). A pesar de que en teoría, disponer de un número mayor de características debería aportar una mayor capacidad discriminante, en la práctica la variable respuesta no es determinada con el conjunto completo de características [168] sino con un subconjunto del mismo $X = \{x_1, x_2, \dots, x_m\}$, donde $m < M$. Algunas de las razones para usar métodos de selección de características pueden ser las siguientes [169]:

- Permitir entrenar al algoritmo propuesto de manera más rápida ya que se reduce la complejidad del procesamiento. Incluso se consiguen reducir las medidas a realizar y los requerimientos de almacenamiento.
- Reducir la complejidad del modelo facilitando su interpretación comprendiendo qué variables o características aportan mayor información del fallo a diagnosticar.
- Mejorar las prestaciones del modelo usando un conjunto más adecuado de características. En muchas ocasiones, las variables redundantes deterioran el rendimiento del clasificador, pero no siempre.
- Reducir el sobreajuste para conseguir herramientas más robustas ante datos de condiciones ligeramente desviadas a las reproducidas en el laboratorio. Un ajuste excesivo del clasificador a los datos de entrenamiento puede generar malos resultados en el conjunto de prueba si estos contienen ruido.

Por lo tanto, el estudio del comportamiento de los posibles conjuntos de características debe ser primordial para la construcción de la herramienta de diagnóstico. Preferiblemente a una simple optimización de los parámetros de ajuste del modelo para todo el subconjunto de características, es necesario encontrar los parámetros óptimos del modelo también para un subconjunto óptimo de características [170].

Aunque en otros campos se ha trabajado mucho este tipo de técnicas, en el diagnóstico de fallos en el rotor de MI no ha tenido mucha presencia. Para el diagnóstico de fallos de barras rotas no se suele disponer de conjuntos de datos con un número elevado de características y es presumiblemente por ello que no hayan recibido mucha atención este tipo de técnicas. No obstante, existen muchos aspectos que pueden hacer interesante el uso de estas técnicas de selección de características ya que pueden [171]:

- Proporcionar una mejor definición de la función objetivo.

- Abordar la construcción de características para, por ejemplo, tener características con funciones de densidad gaussianas.
- Ordenar las características según su importancia o capacidad discriminante.
- Hacer una selección multivariada de características.
- Servir como métodos eficientes de búsqueda.
- Usarse como métodos de evaluación de la validez de las características.

En los siguientes apartados se presentan varios métodos o pruebas usadas para el estudio de las características a seleccionar.

4.3.1. Métodos de filtrado para la selección de características.

Principalmente existen tres clases de métodos de selección de características: métodos embebidos (*embedded methods*), métodos envoltorio (*wrapper methods*) y métodos de filtrado. Los métodos de filtrado se basan en la estimación de una métrica de interés calculada directamente del conjunto de datos, sin recibir retroalimentación directa de un clasificador construido a partir de un algoritmo de aprendizaje. Lo interesante de este tipo de algoritmos es que requieren de mucho menos coste computacional que el resto de métodos. Los métodos de filtrado calculan un índice de relevancia (ya esté relacionado con la información, consistencia o similitud entre características), una métrica de distancia o una medida estadística que puede ser combinada con uno de los otros dos métodos. Nótese que, en este trabajo, por relevancia se entiende lo siguiente: una característica X es relevante en el proceso de distinguir una clase $Y = y$ de otras, si y solo si para algunos valores de $X = x$ para los cuales $P(X = x) > 0$ la probabilidad condicional $P(Y = y|X = x)$ es diferente que la probabilidad incondicional $P(Y = y)$.

Los índices de relevancia son calculados para cada característica individual $X_i, i = 1, \dots, N$, proporcionando un ordenamiento de los mismos $J(X_{i_1}) \leq J(X_{i_2}) \dots \leq J(X_{i_N})$. Aquellas características por debajo de un umbral establecido son filtradas. Esto resulta suficiente para características estadísticamente independientes. Sin embargo, si las características están correlacionadas muchas de ellas pueden resultar redundantes.

No obstante, ordenar las características no garantiza que se encuentre el conjunto más grande de características importantes. Además, dado que no existe experiencia empírica sobre qué métodos de filtrado funcionan mejor y para qué clasificadores, a continuación, se realizan varios estudios de métodos de filtrado para diferentes índices de relevancia.

4.3.1.1. Métodos de filtrado basados en el análisis de correlación.

Los métodos de correlación son quizás el enfoque más simple para ordenar las variables acorde a su importancia. A diferencia de otras técnicas como la información teórica y árboles de decisión, el análisis de correlación evita problemas con la estimación de las densidades de probabilidad así como la discretización de características continuas y, por tanto, puede ser usado como una primera etapa para filtrar las características menos relevantes.

El análisis de los coeficientes de correlación lineal de Pearson, definidos como (4.6) cuantifica la dependencia lineal entre dos variables aleatorias continuas x_1 y x_2 que no tienen por qué seguir una distribución normal. En (4.6) $\text{cov}(X_1, X_2)$ designa la covarianza de las variables del rango y σ_{X_i} la desviación estándar. ρ_{X_1, X_2} toma valores en el rango $(-1, 1)$. Los valores próximos a cero indican ausencia de correlación. Un criterio de corte habitual es un valor entre 0.75 y 0.9.

$$\rho_{X_1, X_2} = \frac{\text{cov}(X_1, X_2)}{\sigma_{X_1} \sigma_{X_2}} \quad (4.6)$$

Sin embargo, este criterio de correlación sólo puede detectar dependencias lineales entre una característica en particular y su variable respuesta. Con el fin de analizar varias técnicas de filtrado, en esta tesis se van a emplear los siguientes métodos:

- Un método de filtrado que esté relacionado con la información aportada por las características: Ganancia de Información.
- Un método de filtrado basado en medidas estadísticas: Análisis de Varianza.
- Un método de filtrado basado en medidas de distancia entre características: algoritmo *Relief-F*.

4.3.1.2. Criterio de la ganancia de información (*Information-Gain*).

Algunos de los índices más usados para evaluar características son aquellos basados en la teoría de la información. La información, que es lo mismo que la negación de la entropía, contenida en la distribución de la clase es:

$$H(Y) = - \sum_{i=1}^K P(y_i) \log_2 P(y_i) \quad (4.7)$$

donde $P(y_i) = \frac{1}{m}$ es la fracción de muestras x de la clase y_i , $i = 1 \dots K$. La misma expresión se usa para la distribución discreta de características X . Para calcular la información asociada

a características continuas es necesario discretizarlas agrupándolas en “bins” o se las puede ajustar con funciones “kernel” para aproximar su función de densidad transformando en este caso la suma en una integral. La información contenida en la distribución conjunta de las clases y las características, sumada sobre todas las clases, da una estimación de la importancia de la característica. La información contenida en la distribución conjunta es:

$$H(X, Y) = - \sum_i \sum_{j=1}^K P(y_i, x_i) \log_2 P(y_j, x_j) \quad (4.8)$$

siendo para las características continuas:

$$H(X, Y) = - \sum_{j=1}^K \int P(y_i, x) \log_2 P(y_j, x) \quad (4.9)$$

donde $P(y_j, x_j), j = 1, \dots, K$ es la probabilidad conjunta (densidad para las características continuas) de encontrar el valor de la característica $X = x_i$ para los vectores x que pertenecen a alguna clase y_j ; y $P(x_i)$ es la probabilidad (o densidad en su caso) de encontrar vectores con valor de la característica $X = x_i$. Valores pequeños de $H(X, Y)$ indican que los vectores de una sola clase dominan en algunos intervalos, haciendo a la característica más apta para la predicción. La información es aditiva para las variables aleatorias independientes. La diferencia $GI(Y, X) = H(Y) + H(X) - H(Y, X)$ puede ser usada como ganancia de información (GI) o información mutua. La fórmula estándar de la GI se puede expresar de la siguiente manera:

$$\begin{aligned} GI(Y, X) &= H(Y) - H(Y | X) = H(Y) + \sum_{i,j} P(y_i, x_i) \log_2 P(y_j | x_i) = \\ &= H(Y) - \sum_{i,j} P(x_i) [-P(y_j | x_i) \log_2 P(y_j | x_i)] \end{aligned} \quad (4.10)$$

Una característica es más importante si la ganancia de información $GI(Y, X)$ entre las distribuciones de la variable respuesta y la característica son más grandes.

4.3.1.3. Análisis de Varianza o *ANalysis of VAriance* (ANOVA).

Aunque el análisis ANOVA fue introducido hace bastante tiempo, es una herramienta muy útil para comparar grupos. Tanto es así que el análisis ANOVA junto con modelos aditivos ya ha sido empleado para analizar las firmas de fallo de MI alimentados por inversor [120]. Por lo tanto, esta técnica puede resultar apropiada para obtener información de las firmas

de fallo empleadas en la presente tesis. El análisis de varianza permite probar la hipótesis de si las medias de dos o más poblaciones son iguales. Los ANOVA sirven para evaluar la importancia de una o más características ya que comparan las medias de la variable respuesta en los diferentes niveles de los factores. La hipótesis nula establece que todas las medias de la población (medias de los niveles de los factores) son iguales mientras que la hipótesis alternativa establece que al menos una es diferente. La expresión simplificada para realizar un análisis ANOVA es la siguiente [172]:

$$F = \frac{\sum_i n_i (\bar{Y}_i - \bar{Y})^2 / (K - 1)}{\sum_{ij} (Y_{ij} - \bar{Y}_i)^2 / (N - K)} \quad (4.11)$$

donde n es el número de observaciones del grupo i , \bar{Y}_i es la media del grupo i , \bar{Y} es la media total, Y_{ij} es la observación j en el grupo i , N es el número total de observaciones y K es el número de grupos.

4.3.1.4. Algoritmo *Relief-F*.

Originalmente, el algoritmo *Relief* [173, 174], fue desarrollado para estimar la calidad de las características (tanto discretas como continuas) en problemas de dos clases. La principal característica de *Relief* es que es sensible a interacciones entre características ponderando cada una de ellas. La idea principal de esta familia de algoritmos se basa en ponderar cada característica estimando cómo de bien el valor de la característica ayuda a distinguir entre observaciones que están próximas entre sí [168, 173, 175]. Para una observación dada, *Relief* busca sus dos vecinos más cercanos: uno de la misma clase y el otro de diferente clase. La ponderación de la característica o el índice de relevancia de este algoritmo $J_R(X)$ para una característica X , se incrementa por una pequeña cantidad proporcional a la diferencia $|X(x) - X(x_d)|$ ya que su relevancia debería crecer para aquellas características que separan vectores de diferente clase, y se reduce por una pequeña cantidad proporcional a $|X(x) - X(x_s)|$. Por tanto, el índice de relevancia para este algoritmo puede ser definido de la siguiente manera:

$$J_R(X) \leftarrow J_R(X) + \eta (|X(x) - X(x_d)| - |X(x) - X(x_s)|) \quad (4.12)$$

donde η es el orden de $\frac{1}{m}$, siendo m el número de observaciones. Después de un número grande de iteraciones, este índice captura las correlaciones locales entre los valores de la característica y su habilidad para ayudar a discriminar los vectores de las diferentes clases.

Dada la utilidad que tiene este algoritmo, en esta tesis se emplea una extensión del mismo denominada *Relief-F* [173], que permite su empleo en problemas de clasificación multi-clase

y está basado en los k -vecinos más cercanos de la misma clase, y el número de vectores de diferentes clases. *Relief-F* es más robusto a la presencia de ruido en los datos y se define en [175] de la siguiente manera:

$$J_R(X) \leftarrow J_R(X) - \eta \left(|X(x) - X(x_d)| + \sum_{Y_i \neq Y_j} P(Y_i) \times |X(x) - X_{Y_i}(x_s)| \right) \quad (4.13)$$

Este tipo de algoritmos *Relief* representa un enfoque diferente para la selección de características que no está basado en la evaluación de una densidad de probabilidad unidimensional, sino en encontrar los vecinos más cercanos, lo que asegura que los pesos de las características sean sensibles al entorno, siendo aún índices globales.

Hasta ahora se han introducido los métodos de filtrado que se van a emplear y que ayudan a ordenar las características de análisis. Sin embargo, el establecimiento del umbral de corte de la ordenación de las características no es una tarea trivial. En esta tesis, se propone una técnica de selección de características basada en el algoritmo RF para evaluar la importancia de las características por medio de la eliminación recursiva de características la cual se describe a continuación.

4.4. Selección de características con *Random Forest* por eliminación recursiva de características.

El método de eliminación recursiva de características o *Recursive Feature Elimination* (RFE) es un método conocido en la literatura como tipo “*wrapper*” el cual es un procedimiento recursivo que ordena las variables según alguna medida de significancia. En el Algoritmo 1 se presenta el pseudocódigo de esta técnica. En cada iteración, se calcula la significancia de la variable, eliminándose aquellas menos pertinentes. Para acelerar el proceso se elimina un grupo de variables cada vez. La recursividad es necesaria para que las medidas de significancia de algunas variables cambien de forma considerable sobre varios subconjuntos de variables. Esto se realiza con un proceso escalonado de eliminación analizando las variables altamente correlacionadas. A continuación, el orden en el que las variables fueron eliminadas es tenido en cuenta para hacer el ranking u ordenación final. El propio procedimiento de selección de características permite determinar para qué número y para qué variables del ranking se obtuvieron las mayores prestaciones de acuerdo a una métrica previamente determinada. Dado que para la elección del umbral se han empleado conjuntos de datos equilibrados, la métrica a

optimizar para su elección será la *Accuracy*. La estabilidad de RFE depende en gran medida del tipo de modelo que se utiliza para el ordenamiento de características en cada iteración. Éste, al igual que la regresión no regularizada, puede llegar a ser inestable [169]. Existen otras técnicas más estables como las técnicas de regresión regularizada que han dado buenos resultados en campos como la medicina [114]. Sin embargo, éstas sólo han dado buenos resultados para conjuntos de datos con muchas características y pocas observaciones.

En este apartado se propone usar el algoritmo RF para llevar a cabo la selección de características en combinación con el método RFE. El algoritmo de bosques aleatorios (*Random forests*) [176] es un ensamble de algoritmos de aprendizaje. La premisa básica del algoritmo se basa en construir árboles de decisión relativamente pequeños de forma aleatoria con pocas características por medio de la técnica *Bootstrap aggregating (Bagging)* [114] y mejorar la eficiencia computacional. Si se construyen muchos árboles de decisión pequeños en paralelo, se pueden combinar sus prestaciones a través de voto mayoritario o promediando y, construir un algoritmo mucho más fuerte. El pseudocódigo del algoritmo se ilustra en Algoritmo 2. Para cada árbol del bosque se selecciona una muestra por medio de *Bootstrap* S_b . Posteriormente, se construye un árbol de decisión haciendo la siguiente modificación en el algoritmo. En cada nodo del árbol, en lugar de examinar todas las posibles particiones de las características, se seleccionan de forma aleatoria un subconjunto $f \subseteq F$ donde F es el conjunto original de características de entrada al algoritmo. Posteriormente el nodo se divide sobre la mejor característica de f en lugar de sobre F . En la práctica f es mucho más pequeño que F . La decisión de elegir sobre qué característica hacer la partición es un aspecto que demanda mucho cómputo en los árboles de decisión.

Algoritmo 1 Algoritmo Random Forest-RFE

Entrada: Datos de entrenamiento: $\mathbf{D} = \{(x_1, y_1), (x_j, y_j), \dots, (x_n, y_n)\}$

Salida: Significancia de las características: $sig(f)$

- 1: Ajuste del modelo usando todas las características con los datos de entrenamiento
 - 2: Cálculo de las prestaciones del modelo
 - 3: Ordenar las características según su importancia
 - 4: **para** Cada conjunto de tamaño $S_i, i = 1, \dots, S$ **hacer**
 - 5: Mantener las S_i variables más importantes
 - 6: Preprocesado de los datos
 - 7: Ajuste del modelo Random Forest: [*Algoritmo 2*] con las S_i características del conjunto de entrenamiento
 - 8: Cálculo de las prestaciones del modelo construido con [*Algoritmo 2*]
 - 9: Recálculo del ranking de cada predictor
 - 10: **fin para**
 - 11: Cálculo del perfil de prestaciones sobre el conjunto S_i
 - 12: Determinar el número apropiado de características
 - 13: Uso del modelo correspondiente con el óptimo S_i
-

Sin embargo, RF lo consigue reduciéndolo a un conjunto f y por tanto acelerando la construcción de los árboles de decisión.

Algoritmo 2 Algoritmo Random Forest (RF)

Entrada: Datos de entrenamiento: $\mathbf{D} = \{(x_1, y_1), (x_j, y_j), \dots, (x_n, y_n)\}$;

características S_i ; número de árboles aleatorios B

Salida: Predicción de clase con RF: $\hat{C}_{RF}(x) = \text{voto mayoritario } \hat{C}_b(x)_1^B$.

1: **para** Cada muestra $b \in 1, \dots, B$ **hacer**

2: $S_b \leftarrow$ Muestra b obtenida por Bootstrap del conjunto S

3: Construir $T_b \leftarrow$ Árbol aleatorio (S_b, F) repitiendo de forma recursiva los siguientes pasos para cada nodo terminal del árbol hasta alcanzar el tamaño mínimo del nodo:

1. Seleccionar f características aleatorias de F con $f \ll F$
2. Escoger la mejor característica de las f para la partición del nodo
3. Partir el nodo en dos nodos hijos

4: **fin para**

5: Ensamble de árboles $T_{b_1}^B$

6: Predicción de una nueva muestra x :

$$\hat{C}_{RF}(x) = \text{voto mayoritario } \hat{C}_b(x)_1^B$$

Siendo $\hat{C}_b(x)$ la predicción de clase del b -ésimo RF.

La técnica *Bagging* sobre la que se basa este algoritmo promedia muchos modelos ruidosos pero carentes de sesgo y, por tanto, logra reducir la varianza [114]. El algoritmo más empleado con *Bagging* suelen ser los árboles de decisión ya que capturan la interacción compleja de la estructura de los datos llegando a tener un sesgo muy bajo si la profundidad es suficientemente grande. Los ensambles son más efectivos cuando los modelos individuales que los componen no están correlacionados. Con la técnica tradicional de *Bagging* los árboles de decisión pueden llegar a estar muy correlacionados ya que las mismas características tienden a ser utilizadas repetidamente para dividir las muestras del *Boostrap*. Sin embargo, con RF al restringir cada partición a una muestra pequeña y aleatoria de características, se puede disminuir la correlación entre los árboles del conjunto. Además, al restringir las características consideradas en cada nodo, se puede construir cada árbol de forma más rápida en menor tiempo. Por lo tanto, esto no sólo permite construir muchos más árboles utilizando el algoritmo de aprendizaje de bosque aleatorio sino que, también consigue que estén menos correlacionados.

Recapitulando, en esta sección se han introducido varios métodos de filtrado y un método para la selección de características basado en el algoritmo RF. Ambos tipos de métodos serán analizados para comparar sus resultados en función de la fuente de alimentación. La principal ventaja de RF-RFE es su menor costo computacional con respecto a los métodos de búsqueda exhaustiva ya que el clasificador RF es evaluado con un conjunto menor de características respecto al original. Por esta razón, el método RF-RFE es la técnica elegida y empleada para la selección de las características protagonistas en la etapa de clasificación.

Método	Ventajas	Desventajas
Ganancia de Información	<ul style="list-style-type: none"> ▪ Rápido. ▪ Escalable a bases de datos de muchas dimensiones ▪ Independiente del clasificador ▪ Computacionalmente simple. 	<ul style="list-style-type: none"> ▪ Ignora las dependencias entre características. ▪ Ignora interacción con el clasificador.
ANOVA	<ul style="list-style-type: none"> ▪ Rápido. ▪ Escalable, univariado y paramétrico. ▪ Independiente del clasificador ▪ Computacionalmente simple. 	<ul style="list-style-type: none"> ▪ Ignora las dependencias entre características. ▪ Ignora interacción con el clasificador.
Relief-F	<ul style="list-style-type: none"> ▪ Modela dependencia entre características. ▪ Independiente del clasificador. ▪ Menor complejidad computacional que los métodos evolutivos. 	<ul style="list-style-type: none"> ▪ Ignora las dependencias entre características. ▪ Ignora interacción con el clasificador.
RFE-Random Forest	<ul style="list-style-type: none"> ▪ Menos propenso a estancarse en un óptimo local. ▪ Interacciona con el clasificador (<i>Random Forest</i>). ▪ Modela dependencias entre características. 	<ul style="list-style-type: none"> ▪ Computacionalmente intenso aunque aminorado por el clasificador <i>Random Forest</i>. ▪ Depende de la selección del clasificador. ▪ Mayor riesgo de sobreajuste respecto a los algoritmos deterministas.

Tabla 4.2: Análisis de las ventajas y desventajas de los diferentes métodos de selección de características.

4.5. Propuesta metodológica para diagnóstico de motores con conjuntos de datos pequeños y clases desequilibradas.

Una vez seleccionadas las variables o características más útiles para construir la herramienta de clasificación se propone una nueva metodología para abordar el problema del diagnóstico con conjuntos pequeños de datos y clases desequilibradas constituida por los algoritmos que se desarrollan a continuación.

4.5.1. Técnicas de muestreo en condiciones de desequilibrio de clases.

Dentro del campo de la ciencia de datos, varios grupos de técnicas se han presentado para tratar el problema de clasificación ante condiciones de desequilibrio de clases donde las observaciones pertenecientes a una clase (clase mayoritaria) son mucho más numerosas respecto a la otra clase con un número bastante menor de observaciones (clase minoritaria). La forma de caracterizar el desequilibrio de clase se realiza a través del ratio de desequilibrio o *imbalance ratio* (IR) [128] el cual es definido como el número de observaciones de la clase del motor en estado sano sobre aquellas correspondientes a la clase de fallo. Aunque bien es cierto que, en campos como la ciencia de datos, score de crédito, medicina, etc., los desequilibrios se caracterizan por valores relativamente elevados ($IR = 100, 1000, etc.$); en esta tesis se escogen los IR de manera razonable en base al tiempo disponible para la captura de las señales experimentales para obtener una variabilidad de casos que permitan analizar la influencia de las fuentes de alimentación y la carga conectada al motor.

Muchos enfoques diferentes se han propuesto para resolver este problema en otros campos, y la literatura es extensa en este sentido [177, 178]. Uno de los principales métodos se basa en el clásico muestreo, donde el objetivo es muestrear un conjunto original de datos con clases desequilibradas para obtener un conjunto de entrenamiento con datos de clases equilibradas [128, 177, 178]. Estos métodos se basan en el sub-muestreo (*under-sampling*) o sobremuestreo (*over-sampling*) de una clase de manera aleatoria [128]. Sin embargo, el muestreo aleatorio presenta algunas desventajas que pueden ir en perjuicio de la herramienta de diagnóstico. Por un lado, las técnicas de sub-muestreo pierden información valiosa obtenida durante la fase de adquisición de datos, pudiendo resultar útil para la inducción del clasificador. Por otro lado, las técnicas de sobre-muestreo hacen copias literales de las observaciones de las clases minoritarias lo que puede conducir al clasificador a incurrir en sobreajuste (*overfitting*) [177, 178]. Es decir, por ejemplo, cuando un clasificador basado en reglas o un clasificador

basado en árboles de decisión se construye aparentemente de manera precisa, mientras que en realidad lo que está haciendo es ocultar la réplica de la observación considerada. Para evitar estos inconvenientes, en esta tesis se va a emplear un método conocido como técnica de sobremuestreo sintético de muestras de la clase minoritaria (Synthetic Minority Over-sampling Technique (SMOTE)) [179] que combina el sobre-muestreo de la clase inusual o clase de fallo (minoritaria) con el sub-muestreo de la clase normal o clase de estado sano del motor (mayoritaria) a través de la generación sintética de ejemplos adicionales. Esta técnica se presenta en el siguiente apartado.

4.5.2. *Synthetic Minority Over-sampling Technique (SMOTE).*

Teniendo en cuenta el marco para el cual se va a desarrollar la herramienta de diagnóstico, se va a emplear un enfoque basado en SMOTE para la construcción de clasificadores supervisados para el diagnóstico de fallos en MI. Partiendo de la construcción de una base de datos con conjuntos de entrenamiento con clases desequilibradas se va a tratar de ampliar las regiones de decisión de cada una de las clases a diagnosticar. Para este propósito se usa e implementa la técnica SMOTE para un conjunto de datos real obtenido con pruebas procesadas de laboratorio. Este algoritmo, propuesto en [179], consiste en un sobremuestreo de la clase minoritaria mediante la creación de observaciones sintéticas evitando duplicar las observaciones conocidas de la clase de fallo. SMOTE está motivado por una técnica que demostró tener éxito en otros campos como, por ejemplo, el reconocimiento de caracteres manuscritos [180]. Sin embargo, con SMOTE lo que se pretende es que las observaciones sintéticas sean producidas en el espacio de características en lugar de con los datos primarios obtenidos. Las instancias de la clase de fallo son sobre-muestreadas tomando cada tupla de características de la clase de fallo con su respectiva variable respuesta a la que corresponden. Esto se realiza introduciendo ejemplos sintéticos a lo largo de los segmentos de la línea que unen cualquiera o todos los k vecinos más cercanos de la clase de fallo de interés. El número de k vecinos más cercanos se optimiza según el número de fallos detectados por el clasificador en cuestión con los datos de entrenamiento, y depende de la cantidad de sobre-muestreo requerido. Para la generación de las muestras sintéticas adicionales se siguen básicamente los siguientes pasos:

1. Cálculo de la diferencia entre la muestra correspondiente a la clase de fallo (vector de características) y sus k vecinos más cercanos de la misma clase. Para las características o variables categóricas, se elige el procedimiento de voto mayoritario para asignar tales valores.

2. Multiplicación del valor anterior por un número aleatorio en el rango (0,1) para a continuación agregárselo al vector de características previamente examinado.

Este procedimiento provoca la selección de un punto aleatorio a lo largo del segmento de línea entre dos vectores de características específicas y, por tanto, crea un grupo sintético de nuevas muestras que permiten lograr el equilibrio de las observaciones de las clases. El algoritmo por tanto, fuerza a la región de decisión de la clase de fallo a volverse más general, dentro de un margen coherente. El pseudo-código de SMOTE se puede apreciar en el Algoritmo 3. Las muestras sintéticas hacen que el clasificador cree regiones de decisión más amplias y menos específicas, en lugar de regiones más pequeñas y más específicas. En consecuencia, el algoritmo de aprendizaje puede ser entrenado con mayor número de observaciones relacionadas con el fallo por medio de la generación sintética de observaciones. En la Fig 4.6 se puede apreciar de manera gráfica el procedimiento de generación de nuevas observaciones de fallo.

Algoritmo 3 SMOTE

Entrada: Número de muestras de la clase de fallo en el conjunto de entrenamiento (clase minoritaria) F ;

cantidad de SMOTE $N\%$; número de vecinos más cercanos k

Salida: Muestras sintéticas de la clase de fallo $\frac{N}{100} \times F$.

- 1: **si** $N < 100$ **entonces**
 - 2: Aleatorizar las muestras de la clase de F
 - 3: $F = \left(\frac{N}{100} \times F\right)$
 - 4: $N = 100$
 - 5: **fin si**
 - 6: $N = (\text{entero})\left(\frac{N}{100}\right)$ {La cantidad de SMOTE se considera un múltiplo entero de 100}
 - 7: $k =$ número de vecinos más cercanos
 - 8: Num_c Número de características
 - 9: $muestra[][]$: array con las muestras de la clase de fallo original
 - 10: Ind_{nuevo} : contador con el número de muestras sintéticas generadas inicializado en 0
 - 11: $Sintetica[][]$: array con muestras sintéticas {Se calculan los k-vecinos más cercanos sólo para la clase de fallo}
 - 12: **para** $i \leftarrow 1, \dots, F$ **hacer**
 - 13: Cálculo de los k -vecinos más cercanos para i , y almacenamiento de índices en $nnarray$
 - 14: Poblar($N, i, nnarray$)
 - 15: **fin para**
 - 16: Poblar($N, i, nnarray$) {Función creada para generar las muestras sintéticas}
 - 17: **mientras** $N \neq 0$ **hacer**
 - 18: Elegir un número aleatorio nn entre 1 y k . Este paso elige uno de los k vecinos más cercanos de i .
 - 19: **para** $c \leftarrow 1, \dots, Num_c$ **hacer**
 - 20: Calcular: $dif = muestra[nnarray][c] - muestra[i][c]$
 - 21: Calcular: $rand =$ número aleatorio entre 0 y 1
 - 22: Calcular: $Sintetica[Ind_{nuevo}][c] = muestra[i][c] + rand \times dif$
 - 23: **fin para**
 - 24: $Ind_{nuevo} = Ind_{nuevo} + 1$
 - 25: $N = N - 1$
 - 26: **fin mientras**
 - 27: Fin de Poblar($N, i, nnarray$)
-

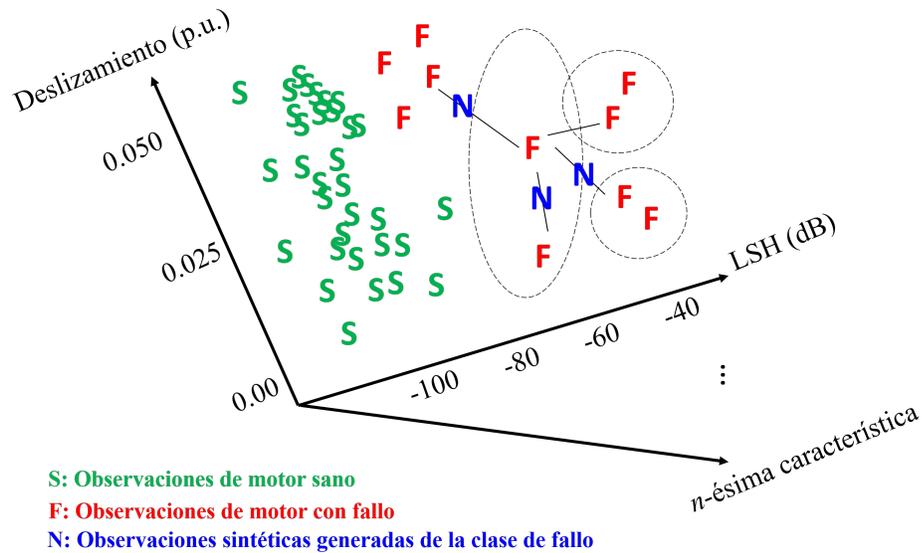


Figura 4.6: Ejemplo de generación bi-dimensional de nuevas observaciones de fallo con SMOTE.

4.5.3. Clasificación con técnicas de *Adaptive Boosting* (*AdaBoost*).

Tras aplicar SMOTE, se dispone de conjuntos de entrenamiento con las clases de la variable respuesta (estado del motor) equilibradas y, el siguiente paso es diseñar un clasificador que tenga buenas prestaciones y que requiera de un número reducido de parámetros de ajuste.

Las técnicas de *Boosting* son técnicas basadas en ensambles (ver Fig. 4.7) que construyen clasificadores base por medio de diferentes muestras de entrenamiento, siendo más idóneas para clasificadores débiles también conocidos como hipótesis. A diferencia de *Bagging*, *Boosting* usa muestras ponderadas para construir diferentes conjuntos de entrenamiento con la muestra actual dependiendo de una etapa anterior. La técnica de *Adaptive Boosting* (*AdaBoost*), propuesta por Freund y Shapire [181], es una técnica de ML que ha dado muy buenos resultados en el reconocimiento de imágenes. La motivación para *AdaBoost* fue un procedimiento basado en *rounds* (ver Fig. 4.8) que utiliza las salidas de muchos algoritmos de base débil para mejorar la predicción de la clase de la variable respuesta a partir de un conjunto de variables. Debido a su capacidad de aprendizaje, *AdaBoost* produce un error empírico exponencialmente decreciente. Las principales ventajas prácticas de *AdaBoost* son:

- *AdaBoost* es un clasificador lineal bastante rápido, fácil de programar.
- El único parámetro de ajuste es el número de rondas o iteraciones.

- El algoritmo es flexible en el sentido de que puede emplear cualquier algoritmo de aprendizaje.
- Tiene buenas propiedades de generalización a través de clasificadores débiles para los que no se requiere conocimiento previo.
- Es versátil. Puede usar varios tipos de datos (discretos, numéricos, etc.) y además se puede extender más allá de la clasificación binaria.

El criterio de parada del algoritmo se escoge de acuerdo a un criterio de tolerancia de error o, simplemente se escoge aquel número de iteraciones para las que el algoritmo obtiene un error sobre el conjunto de prueba más estable.

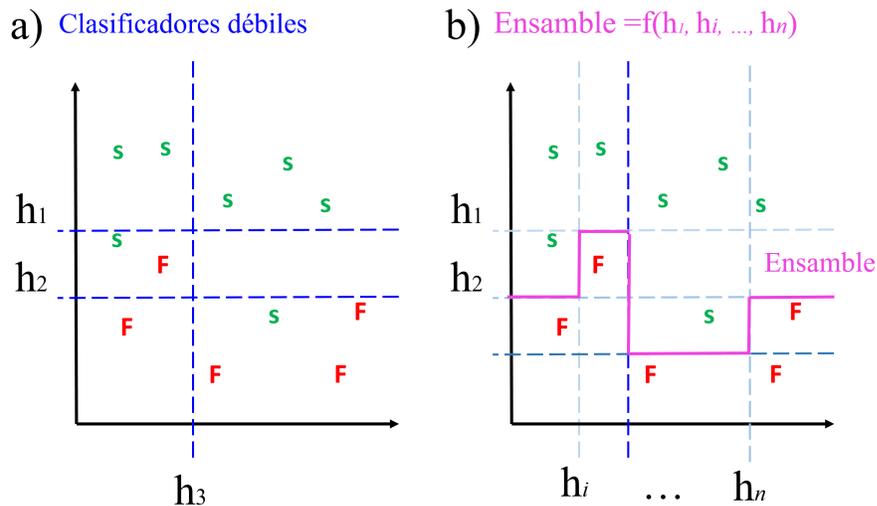


Figura 4.7: Construcción de la ensamble de clasificadores usada por *AdaBoost*: a) Clasificadores débiles; b) Ensamble construida en base a los clasificadores débiles.

Al igual que *Bagging*, este proceso se repetirá K veces. Si it denota cada iteración y α_{it} el peso basado en el error para el it -ésimo clasificador M_{it} , donde w_i^{it} denota el peso para x_i con $w^{it} = (w_1^{it}, w_2^{it}, \dots, w_n^{it})$ siendo el vector de pesos sobre todas las muestras en cada iteración. La selección del peso α_{it} de cada nuevo clasificador débil debe ser positivo. Inicialmente todas las muestras tienen el mismo peso, esto es, tienen la misma probabilidad. Durante cada iteración, la muestra de entrenamiento D_{it} se obtiene por medio de un remuestreo ponderado usando el peso actualizado en la iteración previa. Por tanto, cuanto más pequeño sea el error

de clasificación, más grande es el peso y por tanto el respectivo clasificador débil impactará más en la decisión del clasificador final. Los pesos de las observaciones correctamente clasificadas se reducirán y los pesos de las observaciones clasificadas erróneamente se verán incrementados. Este hecho es importante ya que permite al clasificador atender o enfocarse sobre aquellas observaciones que fueron clasificadas erróneamente en rondas anteriores. El clasificador M_{it} se entrena en D_{it} y su tasa de error ponderado ϵ_{it} es computada sobre todo el conjunto de datos de entrada \mathbf{D} como:

$$\epsilon_{it} = \sum_{i=1}^n w_i^{it-1} I(M_{it}(x_i) \neq y_i), \quad (4.14)$$

donde I es una función indicadora que vale la unidad cuando su argumento se cumple; α_{it} puede ser fijado usando las expresiones de Freund o Breiman [155]. El peso para cada muestra x_i permanece invariable si la clase predicha coincide con la etiqueta de la clase verdadera de la muestra. Sin embargo, si la muestra es clasificada erróneamente:

$$I(M_{it}(x_i) \neq y_i), \quad (4.15)$$

y

$$w_i^{it} = w_i^{it-1} \left(\frac{1}{\epsilon_{it}} - 1 \right), \quad (4.16)$$

su peso varía. Esto significa que si la tasa de error ϵ_{it} es baja, consecuentemente x_i sufre un incremento mayor de su peso. Si el error de un clasificador está próximo a 0.5, como en el caso de clasificadores con prestaciones similares al acierto aleatorio, entonces hay un ligero cambio en el peso y, es de esperar que clasifique de forma errónea muchas observaciones. Por lo tanto, este es el motivo de usar como clasificadores base a aquellos considerados como débiles. Después, los pesos de la muestra w_{it} son actualizados y re-normalizados. Finalmente, una vez construido cada uno de los clasificadores junto a sus respectivos pesos, la etiqueta sobre la muestra u observación de prueba x se obtiene por voto mayoritario. Supóngase que $v_j(x)$ es el voto ponderado para la clase c_j sobre los K clasificadores:

$$v_j(x) = \sum_{it=1}^K \alpha_{it} I(M_{it}(x) \neq c_j) \quad (4.17)$$

El clasificador combinado que predice un problema de clasificación binaria puede obtenerse de la forma indicada en (4.18).

$$M_c(x) = \text{sign} \left(\sum_{i=1}^K M_i(x) \right), \quad (4.18)$$

donde las etiquetas de cada clase son $\{+1, -1\}$. El pseudocódigo de *AdaBoost* puede apreciarse en el Algoritmo 4.

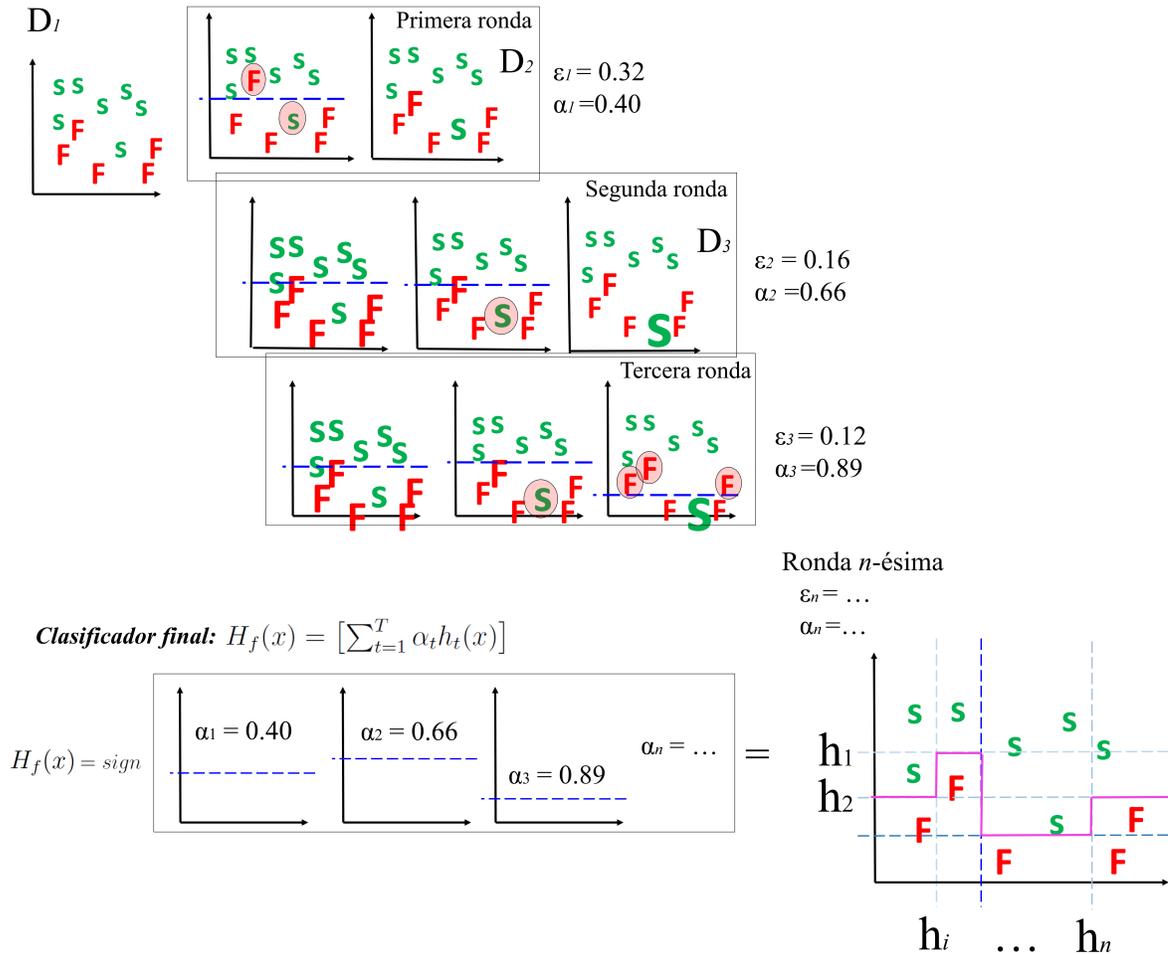


Figura 4.8: Descripción gráfica de la construcción del clasificador *AdaBoost*.

Algoritmo 4 *AdaBoost*.

1. **Entrada:**

- Observaciones etiquetadas del conjunto de entrenamiento
- Elección del clasificador débil: CART, k -NN, etc.
- Función del error: $E(f(x), y, i) = e^{-y_i f(x_i)}$

2. Inicialización del peso de las observaciones del conjunto de entrenamiento $w_i = 1/N$, $i = 1, 2, \dots, N$

3. **Para** $t = 1$ hasta T **hacer:**

a) Ajuste del clasificador $h_t(x)$ al conjunto de entrenamiento con los pesos w_i .

b) Cómputo de:

$$\epsilon_t = \frac{\sum_{i=1}^N w_i I(y_i \neq h_t(x_i))}{\sum_{i=1}^N w_i}.$$

c) Cómputo del coef. de aprendizaje (Breiman): $\alpha_t = \frac{1}{2} \log((1 - \epsilon_t)/\epsilon_t)$.

d) Añadir a la ensamble: $F_t(x) = F_{t-1}(x) + \alpha_t h_t(x)$

e) Actualizar la distribución de los pesos $w_{i,t+1} \leftarrow w_{i,t} \cdot \exp[\alpha_t \cdot I(y_i \neq h_t(x_i))]$, $i = 1, 2, \dots, N$.

f) Re-normalizar $w_{i,t+1}$ tal que $\sum_i w_{i,t+1} = 1$ para mantenerlo como distribución.

4. **fin para**

5. **Salida:** *Clasificador final*

$$H_f(x) = \text{signo}[\sum_{t=1}^T \alpha_t h_t(x)].$$

4.5.4. Integración de las técnicas anteriores para construir la herramienta de diagnóstico.

El esquema integrador de las técnicas propuestas para construir la herramienta de aprendizaje estadístico se muestra en la Fig. 4.9. Como se puede apreciar, inicialmente se parte de un conjunto de datos donde predominan las observaciones pertenecientes a la clase de motor sano. Posteriormente, se aplica SMOTE a un conjunto de datos de entrenamiento con el objetivo de equilibrar las clases por medio de muestras sintéticas y entrenar al clasificador

AdaBoost. Finalmente, el clasificador construido es evaluado a través de las métricas expuestas en apartados anteriores para interpretar las prestaciones de la herramienta de diagnóstico. La forma de obtener los parámetros de ajuste de AdaBoost así como los resultados de la selección de características con RF-RFE será por medio de los procedimientos de validación cruzada y de *Bootstrapping* descritos en el capítulo anterior.

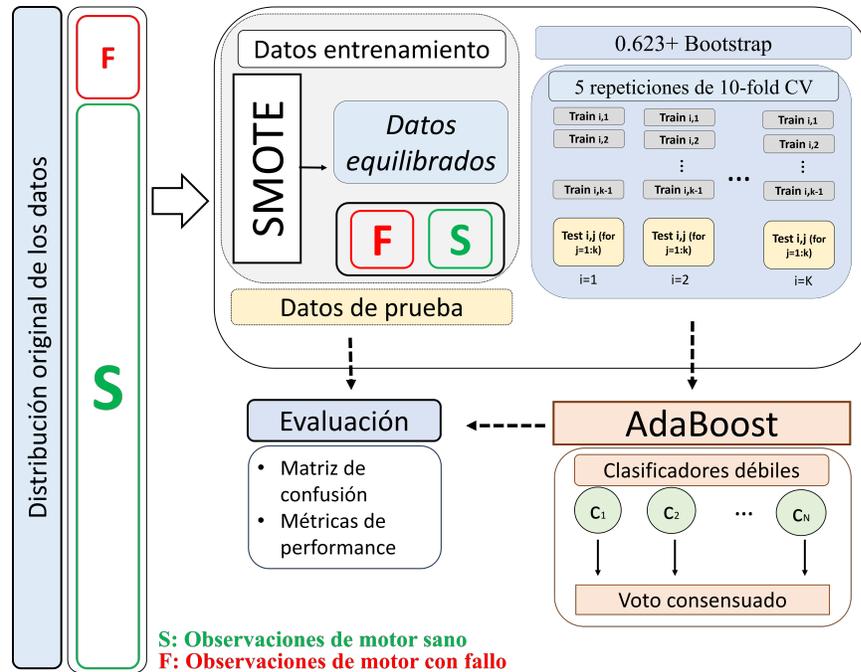


Figura 4.9: Metodología de diagnóstico propuesta para conjuntos de datos desequilibrados.

Capítulo 5

Resultados.

En este capítulo se presentan, primeramente, las características de las señales y ensayos realizados para elaborar los conjuntos de datos necesarios para la construcción y validación de las metodologías propuestas. Después se presentan los principales resultados obtenidos con las propuestas metodológicas.

5.1. Diseño del conjunto de ensayos.

Para resolver la problemática planteada y poder alcanzar los objetivos propuestos, se ha diseñado un banco de ensayos experimental para atender los siguientes aspectos:

- Obtención de datos de varios puntos de funcionamiento del motor según su carga: un nivel de carga medio ($s \simeq 0.03$) y un nivel de carga alto ($s \simeq 0.05$).
- Empleo de un conjunto amplio de fuentes de alimentación para diferentes modos de control incluyendo la compensación por deslizamiento.
- Los estados de severidad del fallo de barra rota, comprenden cinco condiciones: sano, fallo incipiente, fallo de media barra, fallo desarrollado y fallo total de una barra del rotor (ver Fig.5.1). Cada severidad está caracterizada según la profundidad y grosor del taladro efectuado para simular el fallo: R1 (sano, G1), R2 (4.2 mm, G1), R3 (9.4 mm, G1), R4 (17 mm, G1) y R5 (17 mm, G2), siendo G1 un grosor de 2.5 mm de diámetro; y G2 un grosor de 3.5 mm de diámetro.
- Las características de duración del ensayo abarcan tanto el transitorio de arranque como el periodo estacionario posterior.

- Los ensayos se realizaron en un entorno controlado y bajo condiciones muy similares de operación. Los ensayos con valores de corriente y deslizamiento (carga) muy alejados de la tendencia central del grupo fueron repetidos de nuevo. Esto permitió disponer de un conjunto homogéneo de datos para cada condición de operación considerada (ver Apéndice B).

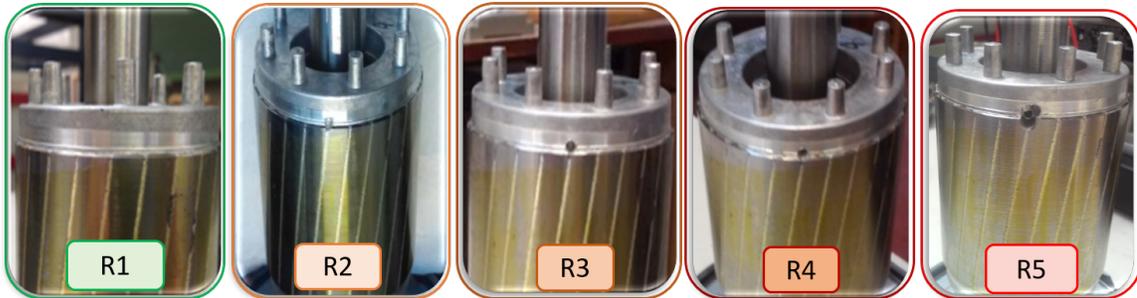


Figura 5.1: Estados del rotor según el taladro realizado.

Atendiendo a los anteriores aspectos y considerando los intereses del Grupo de Investigación según la línea de investigación a seguir en los próximos años, se han realizado ensayos considerando los siguientes parámetros:

- Tipo de control.
- Modalidad de arranque.
- Tipo de modulación del inversor ó diferente frecuencia de modulación.
- Grado de compensación por deslizamiento.
- Fabricante del inversor.

Cada conjunto de ensayos diseñado para validar la herramienta de diagnóstico ha sido construido de la siguiente manera:

- La frecuencia de consigna se ha establecido en 50 Hz.
- Dos niveles de carga denominados NC1 (Medio-Bajo) y NC2 (Alto).
- Se han realizado 30 ensayos con el motor sano (R1) por nivel de carga. Para el resto, se han realizado 15 por nivel de carga.

5.2. Magnitudes monitorizadas.

Como ya se ha indicado, en este trabajo se emplea la corriente estática como señal principal de la que se van a obtener los patrones de fallo. Además, se han capturado varias señales adicionales como la tensión de las tres fases estáticas, la velocidad de giro y el par de carga. A pesar de medir la velocidad, el deslizamiento ha sido calculado por medio de la ubicación de los armónicos de ranura en el espectro de la corriente, lo que facilita su estimación con mayor precisión. El periodo de captura de las señales cubre un transitorio de arranque de 10 segundos y un periodo en régimen estacionario de 20 segundos.

5.3. Ensayos realizados en el laboratorio.

En la Fig. 5.2 se muestra un esquema de las configuraciones de los ensayos realizados.

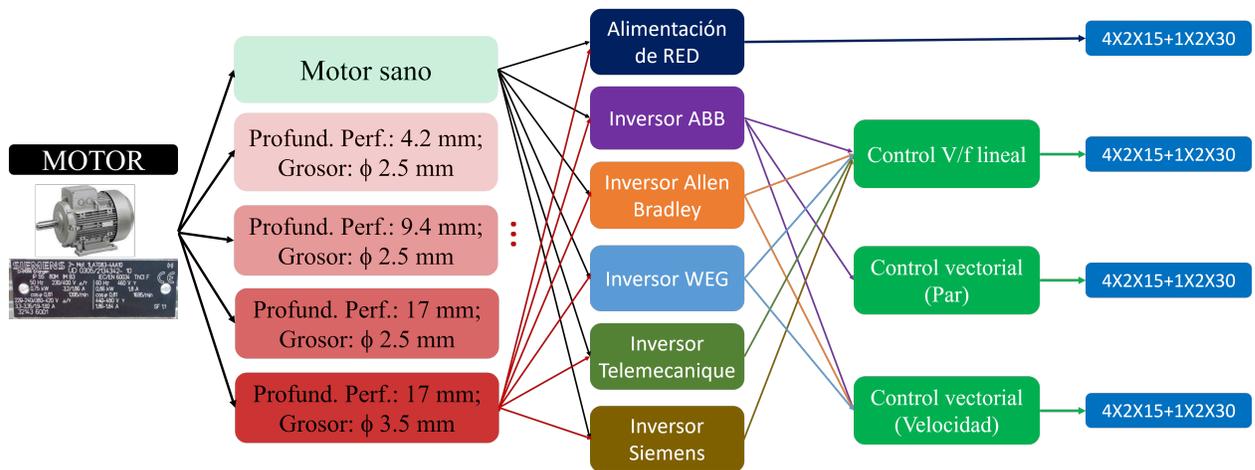


Figura 5.2: Esquema de los ensayos realizados.

Los ensayos de motor sano son:

$$E_{sano} = N_{mod} \times N_{ens,NC} \times N_{NC} = 13 \times 30 \times 2 = 780 \text{ ensayos}$$

Los ensayos realizados del motor con fallo de alguna de las 4 severidades descritas anteriormente es:

$$E_{fallo} = N_{mod} \times N_{ens,NC} \times N_{NC} \times N_{sev} = 13 \times 15 \times 2 \times 4 = 1560 \text{ ensayos}$$

Por lo tanto, el número total de ensayos realizados es de:

$$N_{Tot,ensayos} = E_{sano} + E_{fallo} = 780 + 1560 = 2340 \text{ ensayos}$$

5.4. Elementos que componen el banco de ensayos.

En la Fig. 5.3 se muestra un plano general del banco de ensayos diseñado para la captura de las señales indicadas anteriormente.

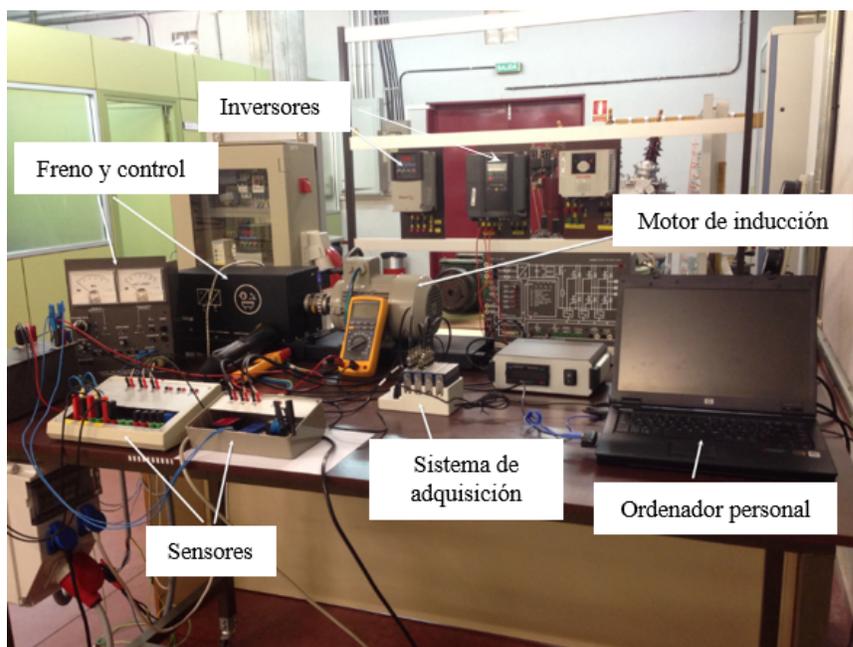


Figura 5.3: Banco de ensayos experimental.

Sobre la misma Fig. 5.3 se indican los principales elementos que componen el banco experimental de pruebas. La máquina ensayada es un MI al que se le ha sometido a un fallo mecánico de barra rota tras tomar las señales correspondientes a su condición de motor sano. Las distintas severidades de fallo se han provocado por medio de una taladradora consiguiendo perforar una barra del rotor para varios grados de severidad (profundidad y grosor) del agujero ocasionado. Cada una de estas severidades, va a servir para validar la metodología propuesta que aborda el diagnóstico automático y temprano de un motor con barra rota falimentado por inversor. El motor es alimentado tanto con inversores como directamente de la red eléctrica. La descripción detallada de los elementos usados para construir el banco de ensayos se describe en el Apéndice A.

5.5. Resultados de la metodología combinada MUSIC-FFT para la detección de fallo incipiente.

El primer paso de esta metodología incluye la localización precisa de las frecuencias de rotura de barra. En la Fig. 5.4 se puede apreciar la dispersión producida en el pseudo-espectro MUSIC cuando se le aplican tres órdenes de MUSIC a un conjunto de señales para una configuración de ensayos particular ante un nivel de carga definido. A modo de ejemplo, en la Fig. 5.4 se presentan los resultados del motor alimentado con inversor Telemecanique (TM) con un nivel de carga alto (NC2) para la severidad de barra (R5). Los órdenes aplicados para obtener los espectros de MUSIC para este caso se pueden consultar en la Tabla 5.1

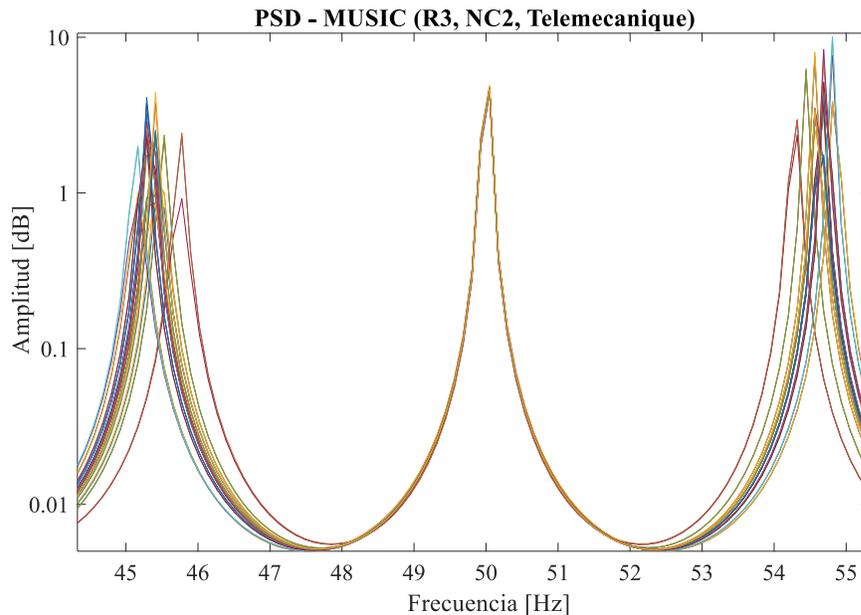


Figura 5.4: Dispersión de los tres órdenes de MUSIC fijados para el conjunto de señales de TM con severidad R5 y NC2.

El siguiente paso consiste en determinar la severidad del fallo a través de la magnitud de las componentes de frecuencia de barra rota. Esto se realiza con la FFT. Como ejemplo, las Figs. 5.5 y 5.6 muestran el PSD de algunas señales procesadas con MUSIC para la localización de las frecuencias de rotura de barra y con la FFT para la estimación de la severidad del rotor. En las figuras se puede apreciar la capacidad discriminante que tienen los órdenes de MUSIC determinados con la metodología propuesta. Los espectros obtenidos con la FFT

muestran cómo el nivel de ruido complica la identificación y extracción de las firmas de fallo mientras que MUSIC mejora la localización de las componentes. Dado que MUSIC es más sensible a los cambios en la severidad del fallo, éste proporciona una observación más fina de la componentes de frecuencia en caso de fallo incipiente (R3). La Tabla 5.1 muestra un resumen de los valores promedio tras procesar las señales estatísticas con la metodología propuesta según el conjunto de señales considerado mostrando los órdenes seleccionados para cada caso. En esta tabla, como firma de fallo se muestra la suma de las amplitudes LSH y RSH.

La Fig. 5.5a-b muestra la PSD de algunas señales de corriente del motor sano con inversor ABB y WEG respectivamente, obtenidas tanto con la FFT como con MUSIC. Por otro lado, la Fig. 5.5c-d y la Fig. 5.5e-f se han obtenido con señales estatísticas donde se ha alimentado al motor con los mismos inversores pero para las condiciones de severidad R3 y R5 respectivamente. Si se comparan los pares de figuras entre sí, se puede apreciar que el caso de barra rota (R5) se detecta perfectamente en ambos casos. Sin embargo, lo más interesante de estos resultados es que, con los órdenes escogidos, se pueden también apreciar, aunque no de forma tan notoria como en el caso anterior, diferencias significativas entre el motor sano y el fallo incipiente R3. Se puede observar que incluso cuando el motor es sano, el espectro obtenido con la FFT arroja armónicos que pueden dar lugar a falsos positivos debido a que se pueden confundir con una situación R3. Sin embargo, el análisis previo realizado con MUSIC, permite discriminar de cierta manera entre un estado y otro evitando incurrir en un falso positivo.

Para hacer un análisis más extremo de la metodología, a continuación se va analizar el caso de un inversor muy ruidoso como es el caso del inversor de Telemecanica frente al caso de alimentación directa de la red. La Fig. 5.6a-b muestran la PSD de algunas señales con el motor sano cuando se alimenta con inversor TM y de la red respectivamente. En primer lugar, es claro que la detección de la barra completamente rota se logra en ambos casos. Sin embargo, el fallo incipiente con alimentación por inversor TM no se puede lograr con el esquema propuesto ya que los órdenes escogidos muestran frecuencias espurias. Incluso, con la FFT se puede observar que el nivel de cesped o del ruido es muy elevado para este inversor. Si se analiza el caso de alimentación de red, se puede observar que los órdenes de MUSIC escogidos discriminan mucho mejor entre el estado sano y el estado incipiente para el nivel de carga NC2. También se aprecia que, para el nivel de carga NC1 y alimentación de red, los tres órdenes escogidos coinciden en identificar las frecuencias de fallo para R3 no siendo así para el caso del motor sano. Este hecho permite que el índice de fallo obtenido con MUSIC

entre los tres órdenes pueda usarse para discriminar entre ambos estados del motor.

Tipo de Alim.	Nivel de carga	Orden de MUSIC	MUSIC ($IF_{LSH} + IF_{RSH}$)			FFT (LSH+RSH)			
			R1	R3	R5	R1	R3	R5	
ABB	NC1	20	0	1	59	-160	-129	-98	
		30	0	4	59				
		40	1	7	58				
	NC2	18	1	19	71	-163	-127	-91	
		24	10	30	70				
		30	15	41	69				
	WEG	NC1	12	1	0	20	-152	-146	-95
			14	2	0	53			
			16	5	1	53			
NC2		16	12	29	66	-153	-133	-89	
		20	29	40	64				
		24	36	44	59				
TM	NC1	80	0	0	43	-128	-129	-100	
		110	0	0	47				
		140	11	13	47				
	NC2	100	0	0	57	-129	-126	-95	
		120	0	1	59				
		130	3	0	60				
RED	NC1	25	3	9	18	-166	-143	-102	
		30	4	13	27				
		35	5	13	30				
	NC2	10	0	1	46	-174	-131	-94	
		12	0	4	52				
		14	10	11	59				

Tabla 5.1: Valores de detectabilidad promedio para la configuración considerada de ensayos después de su procesamiento con MUSIC y con la FFT para los órdenes adoptados y condiciones de carga consideradas.

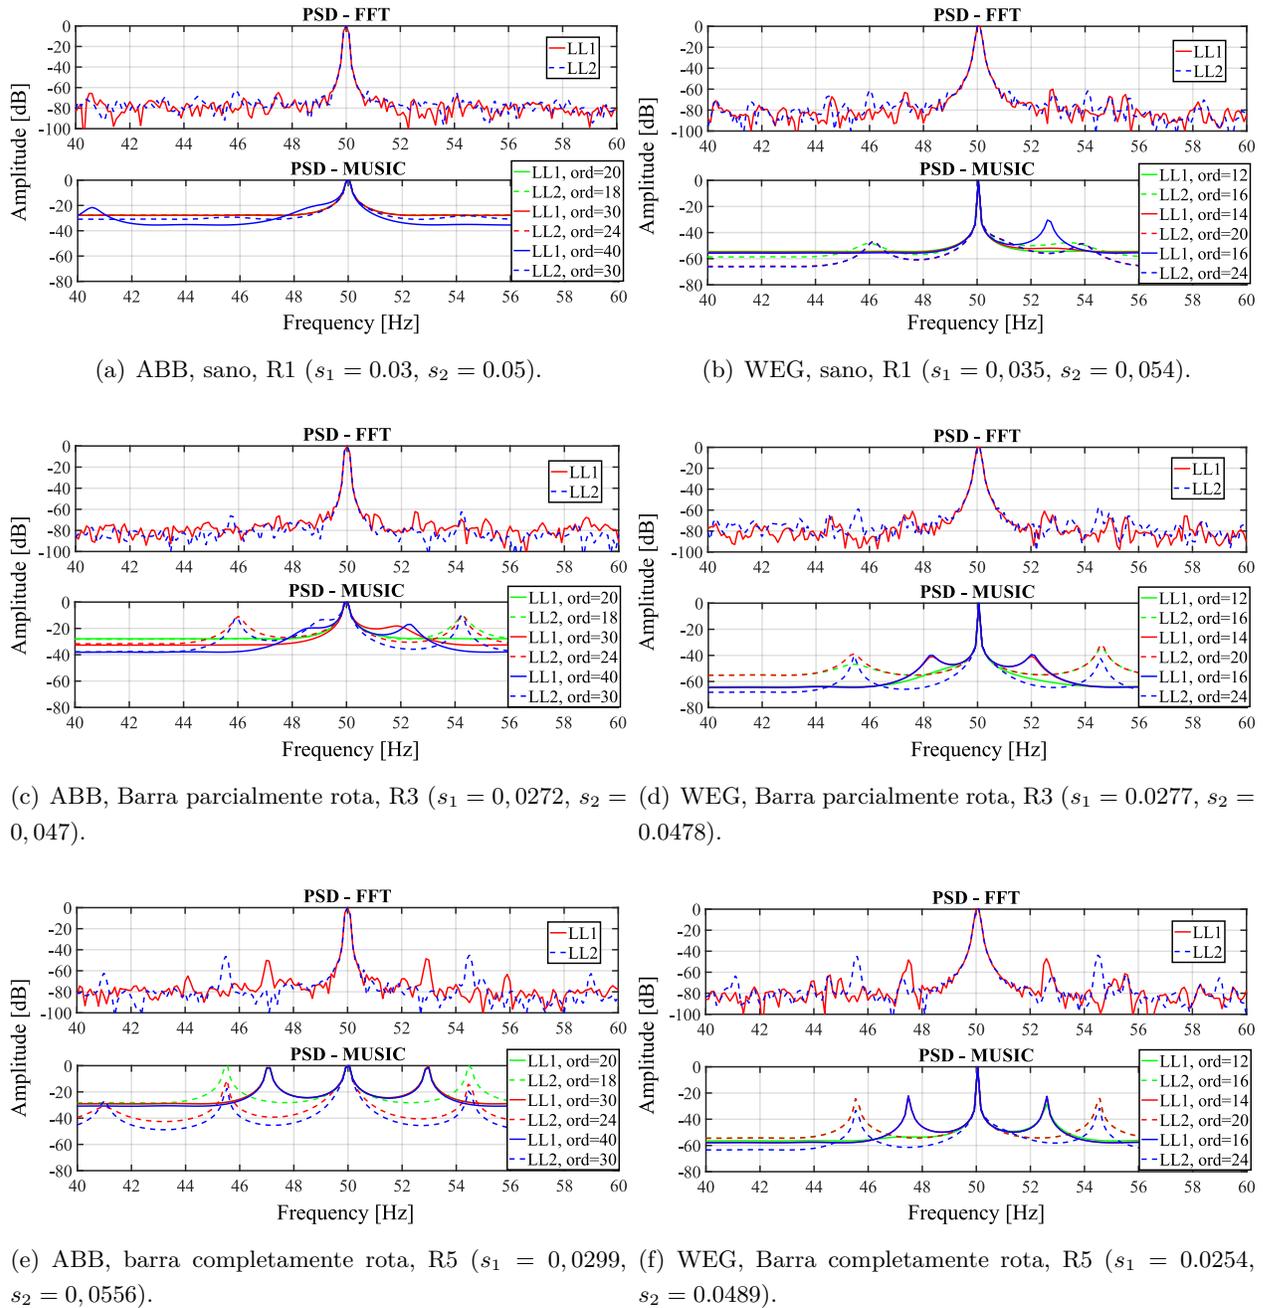


Figura 5.5: Espectros FFT y MUSIC para los suministros ABB y WEG del motor.

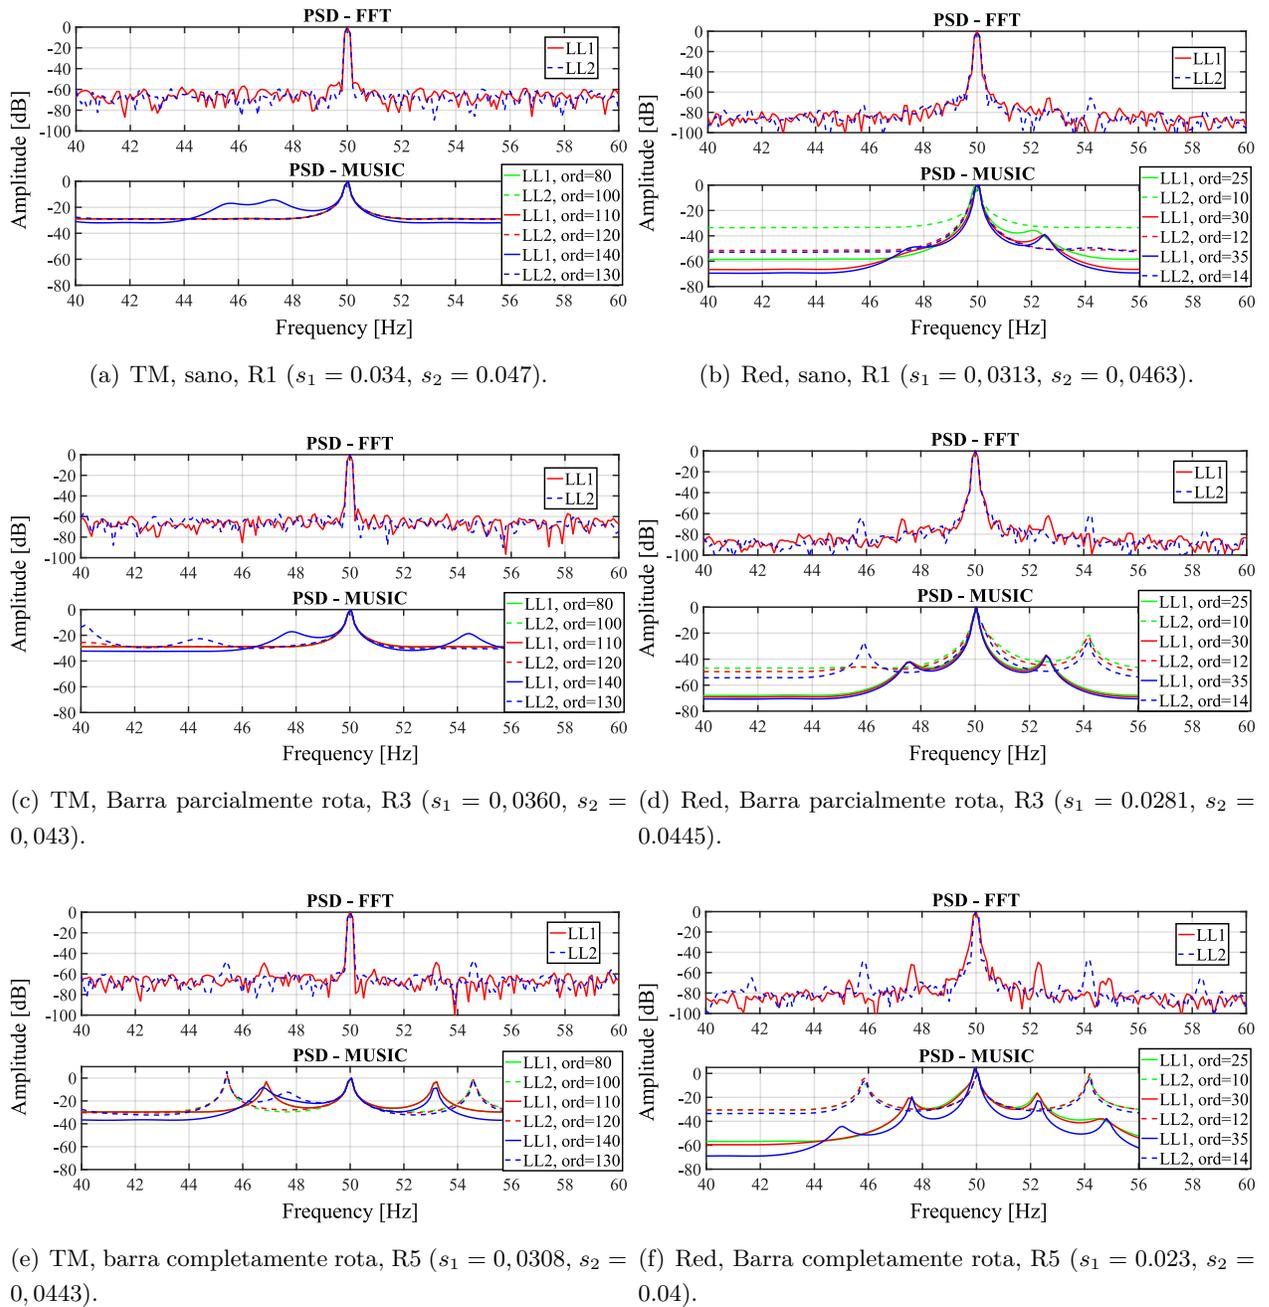


Figura 5.6: Espectros FFT y MUSIC para los suministros TM y de línea del motor.

5.6. Procesamiento de las pruebas y extracción de patrones.

Como es de esperar, el primer paso para desarrollar una herramienta de aprendizaje supervisado es realizar un procesamiento que permita obtener los patrones más relevantes de las pruebas realizadas en el laboratorio. En el siguiente apartado, se presenta el estudio preliminar con algunos resultados de los datos procesados a partir de las señales del motor.

Para tener una idea inicial de cómo las variables calculadas se relacionan entre sí, en la Fig. 5.7 se muestra la correlación existente entre las variables o características cuando el motor es alimentado de red.

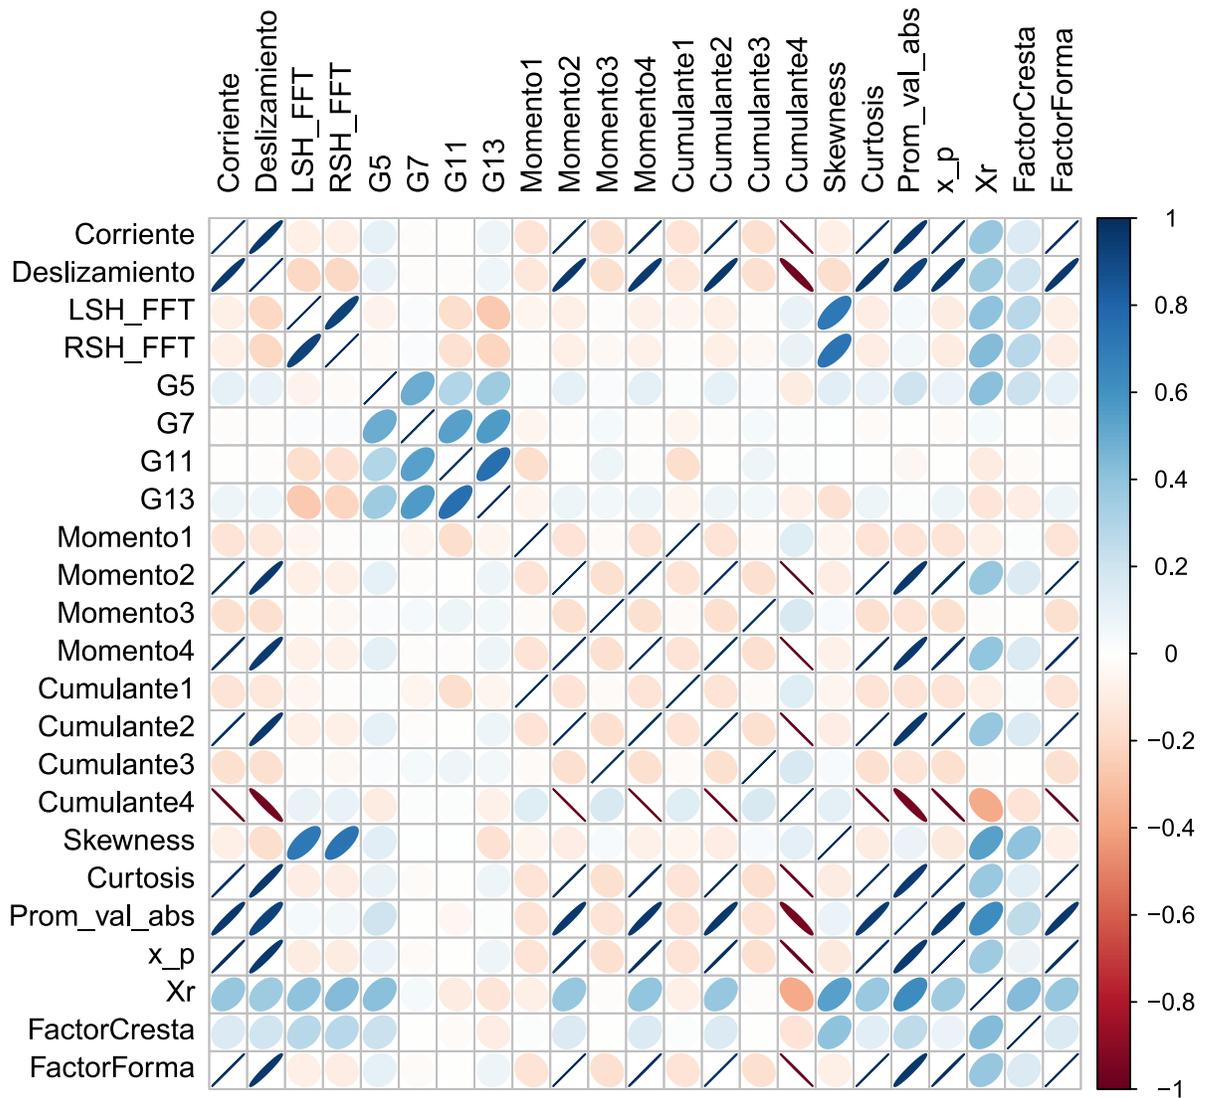


Figura 5.7: Gráfico de correlación de las variables procesadas obtenidas de las señales de laboratorio. Caso de alimentación de red.

Como se puede apreciar y era de esperar, existen variables como la corriente consumida por el motor y el deslizamiento que están muy correlacionadas entre sí. Otra correlación muy importante es entre el LSH y el RSH. Nótese también que llama mucho la atención cómo la corriente está altamente correlacionada con los momentos y cumulantes pares, así como con la curtosis y el factor de forma.

5.7. Análisis de Bandas de Frecuencia.

Tal como se presentó en los Capítulos 2 y 3, las bandas laterales tanto de la componente fundamental como de ciertos armónicos de ésta pueden ser buenos indicadores del estado de la jaula de un MI. Por ello, a continuación se presentan los resultados obtenidos de procesar dichos indicadores sobre el conjunto de ensayos realizado.

5.7.1. Análisis de las bandas laterales de la componente fundamental.

El procedimiento de diagnóstico de fallos basado en la información de las características obtenidas de la señal de corriente del estátor consiste, en primer lugar, en aplicar la etapa de selección de características a una parte de los datos del conjunto de ensayos realizados. Sin embargo, antes de llevar a cabo tal procedimiento es necesario hacer un análisis de las firmas de fallo obtenidas en este contexto de diagnóstico.

En la Fig. 5.8 se puede apreciar la dispersión de los indicadores LSH y RSH en función del deslizamiento para cada nivel de carga considerado cuando el motor es alimentado de la red. Se puede observar cómo para este tipo de alimentación y para ambos niveles de carga, la mayoría de los estados (de R3 a R5) son claramente separables. Sin embargo, el problema parece estar entre la severidad R2 y el estado de motor sano R1. Además, como era de esperar para el nivel de carga NC1 parece que las diferentes severidades son menos separables.

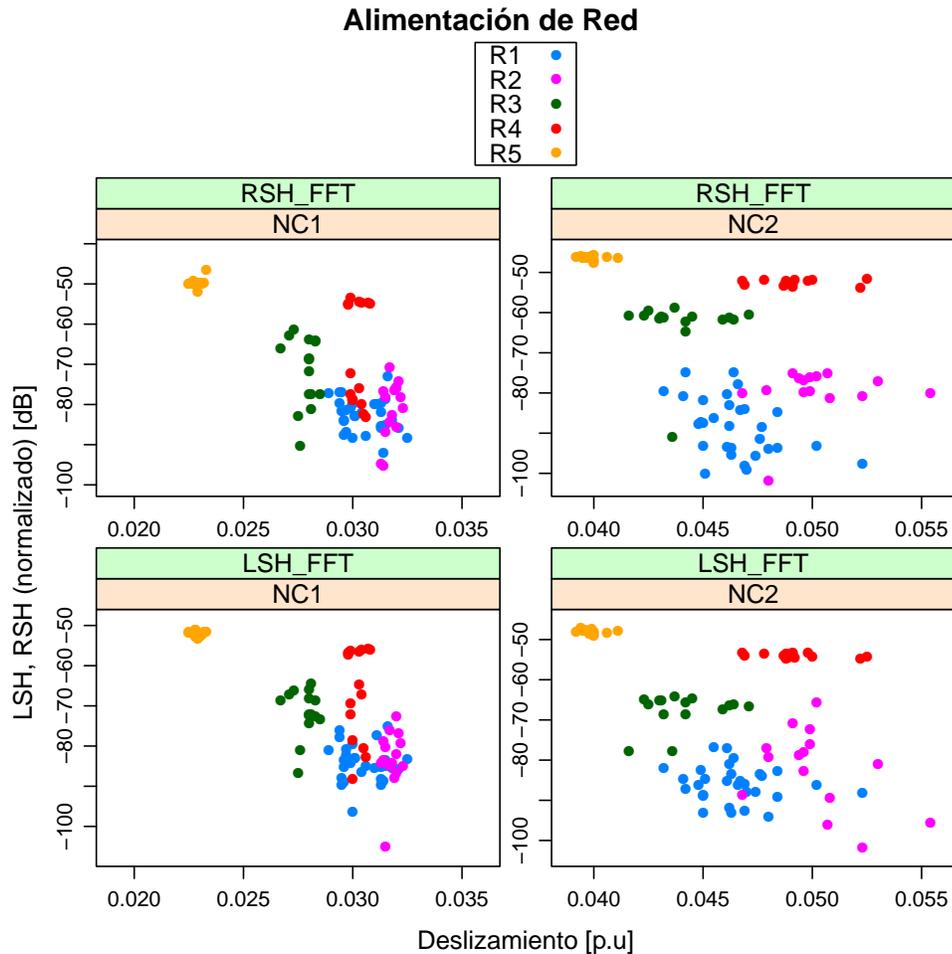


Figura 5.8: Diagrama de dispersión del LSH y RSH vs deslizamiento según el Nivel de Carga. Alimentación de red.

En la Fig. 5.9 se muestra el mismo gráfico anterior donde los indicadores LSH y RSH se representan en función del deslizamiento para cada nivel de carga pero en este caso para la alimentación con el inversor ABB. También se observa que para este tipo de alimentación y para ambos niveles de carga, la mayoría de los estados (de R3 a R5) son separables. El problema sigue siendo separar la severidad R2 y el estado de motor sano R1. En este caso, la separabilidad de las severidades entre niveles de carga no es tan diferenciada.

Si se analiza el caso de alimentación con inversor Allen Bradley (Fig. 5.10) a través del mismo gráfico anterior, se puede apreciar mayor complejidad entre las severidades R1, R2

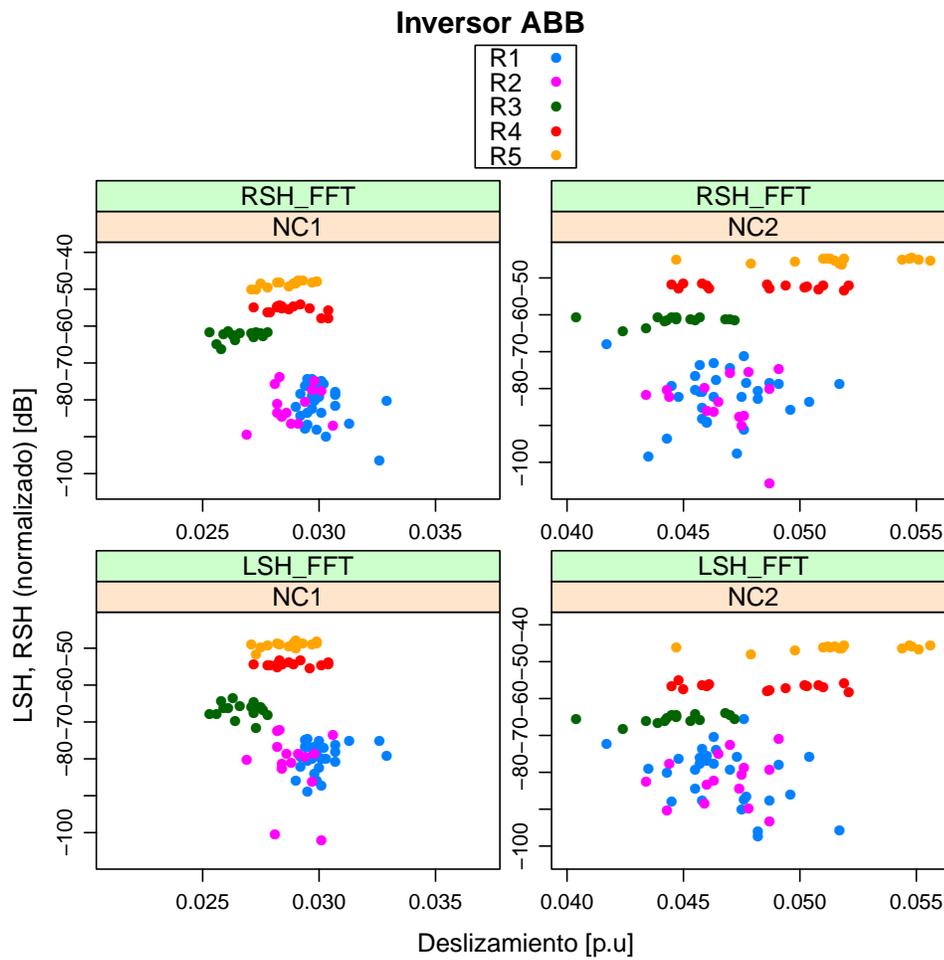


Figura 5.9: Diagrama de dispersión del LSH y RSH vs deslizamiento según el Nivel de Carga. Alimentación ABB.

y R3. En este caso, se observa a simple vista que el indicador RSH resulta ser mejor que el LSH en cuanto a separabilidad entre clases. Finalmente, en la Fig. 5.11 se muestra el diagrama de dispersión de los indicadores LSH y RSH cuando el mismo motor es alimentado con el inversor de Telemecanique. Como se observa este caso es muy complejo incluso para el nivel de carga NC2. Para el nivel de carga NC1 se observa cierta estratificación de las clases en función del deslizamiento. Esto es un inconveniente a tener en cuenta para validar la herramienta de diagnóstico. Se puede inferir que bajo estas condiciones, las técnicas de selección de características escogerán a la variable deslizamiento como variable relevante. Consecuentemente, y debido a la dependencia de los indicadores de fallo con el deslizamiento esta variable debe ser eliminada para fines de clasificación.

5.7.2. Análisis de los indicadores basados en las bandas laterales armónicas superiores al fundamental.

En la Fig. 5.12 se muestra una matriz de figuras donde se puede apreciar varios diagramas de dispersión y funciones de densidad (en la diagonal) entre los indicadores Γ_5 (G5), Γ_7 (G7), Γ_{11} (G11) y Γ_{13} (G13) para cada estado del rotor estudiado con alimentación directa de la red eléctrica.

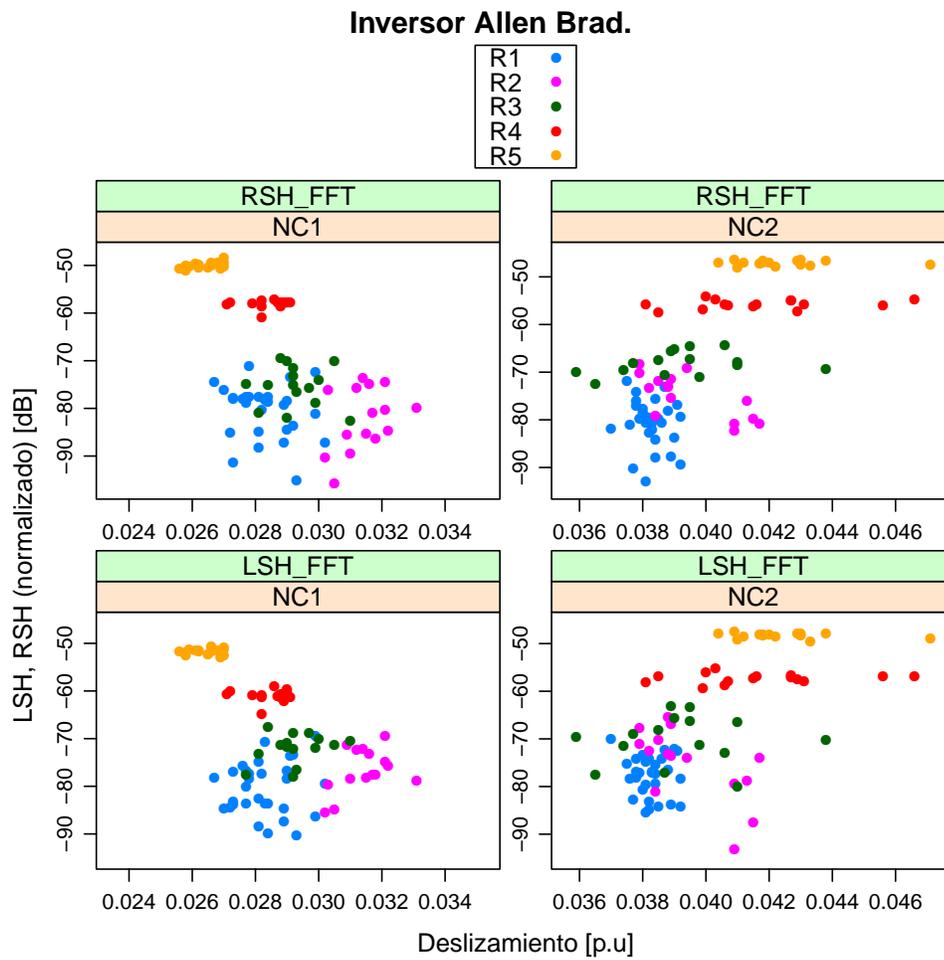


Figura 5.10: Diagrama de dispersión del LSH y RSH vs deslizamiento según el Nivel de Carga. Alimnetación Allen Bradley.

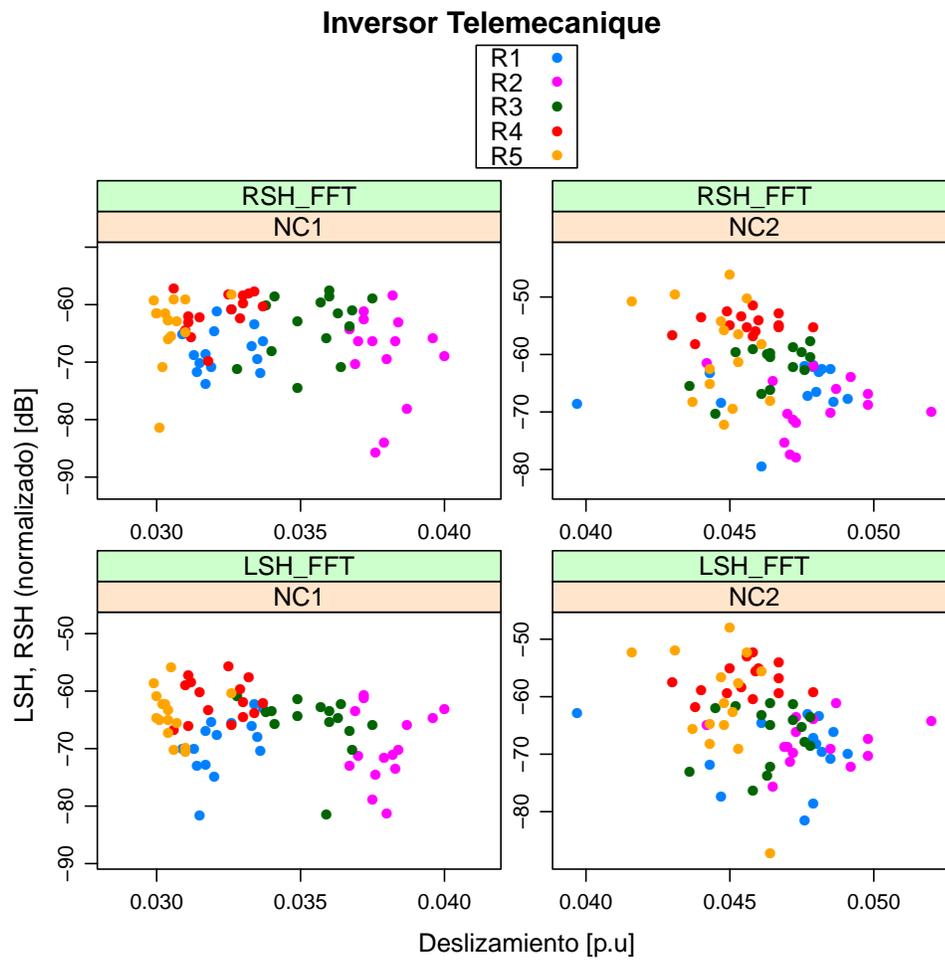


Figura 5.11: Diagrama de dispersión del LSH y RSH vs deslizamiento según el Nivel de Carga. Alimentación Telemecanica.

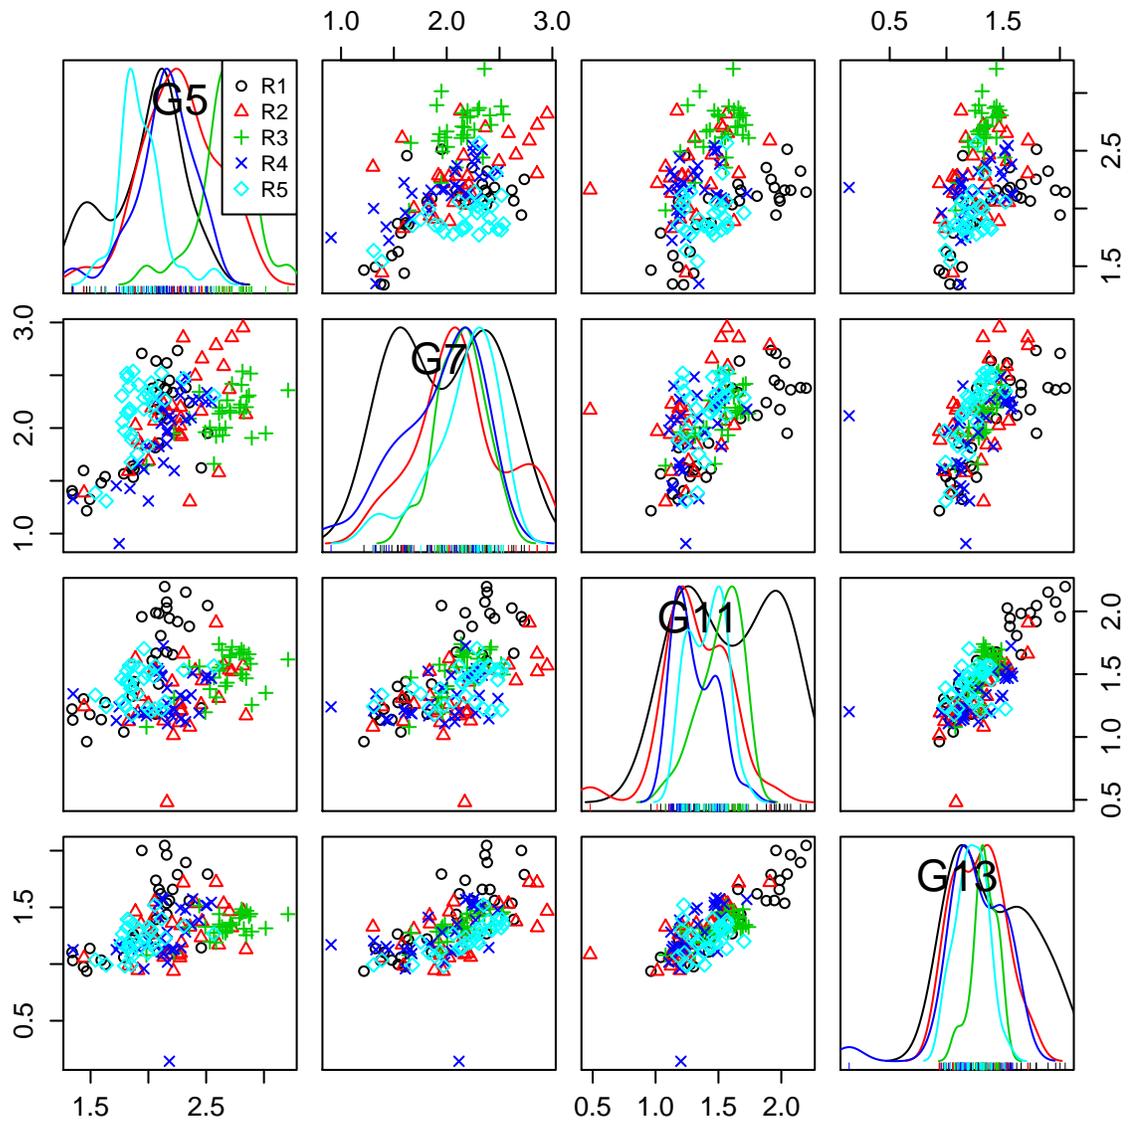


Figura 5.12: Análisis de los parámetros procesados introducidos en [69] bajo alimentación de red.

Como se puede apreciar en la Fig. 5.12, a pesar de que los indicadores no presentan aparentemente una capacidad discriminante clara, pueden resultar útiles para discriminar entre estados del rotor sobre algunas observaciones.

Por otro lado, en la Fig. 5.13 se muestra la relación de los mismos indicadores Γ_5 (G5), Γ_7 (G7), Γ_{11} (G11) y Γ_{13} (G13) pero en este caso bajo alimentación con inversor ABB.

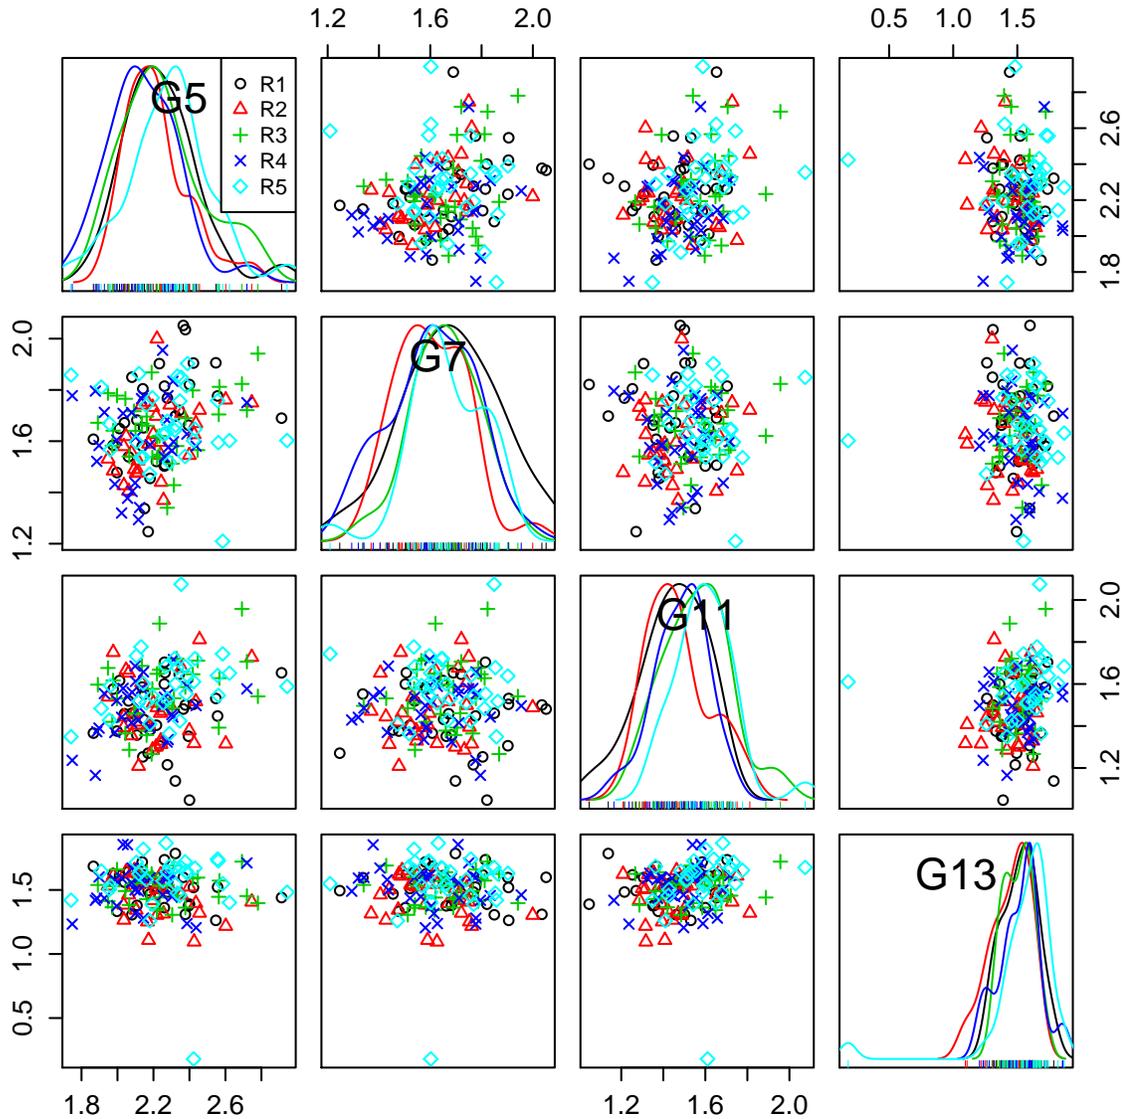


Figura 5.13: Análisis de los parámetros procesados introducidos en [69] bajo alimentación ABB.

Parece ser que *a priori*, para el caso de detección incipiente con alimentación por inversor

ABB (Fig. 5.13) , los indicadores no presentan una capacidad discriminante clara entre severidades del rotor y, por lo tanto, es de esperar que las técnicas de selección de características no los posicionen como principales candidatos. Sin embargo, esta afirmación no se puede garantizar con certeza ya que puede que, junto con otras características, lleguen a resultar útiles para discriminar entre estados del rotor y servir para la etapa de clasificación.

5.8. Resultados de la selección de características.

Como se ha podido observar anteriormente, ninguna de las características previamente examinadas tiene una elevada capacidad de discriminar por sí sola entre todas las severidades y, menos aún para todo el conjunto de fuentes de alimentación consideradas. También se ha observado que la capacidad de las mismas varía mucho de un nivel de carga a otro.

Sin embargo, estas aseveraciones no se han justificado con alguna métrica objetiva y han sido planteadas por mera observación de los diagramas de dispersión de los datos. Por ello, a continuación se presentan los resultados obtenidos con los métodos de filtrado de características descritos en la metodología.

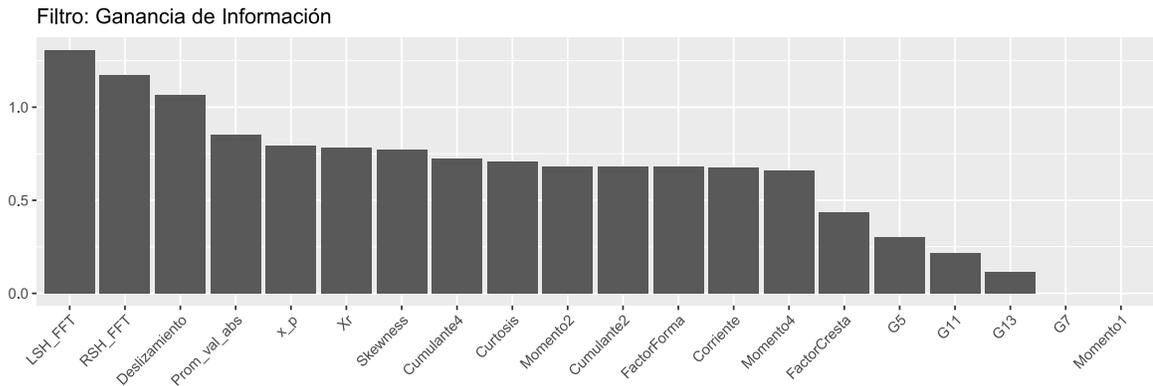
5.8.1. Resultados de la etapa de filtrado.

A continuación, se presentan los resultados obtenidos con las técnicas de filtrado aplicadas para cada tipo de alimentación por separado.

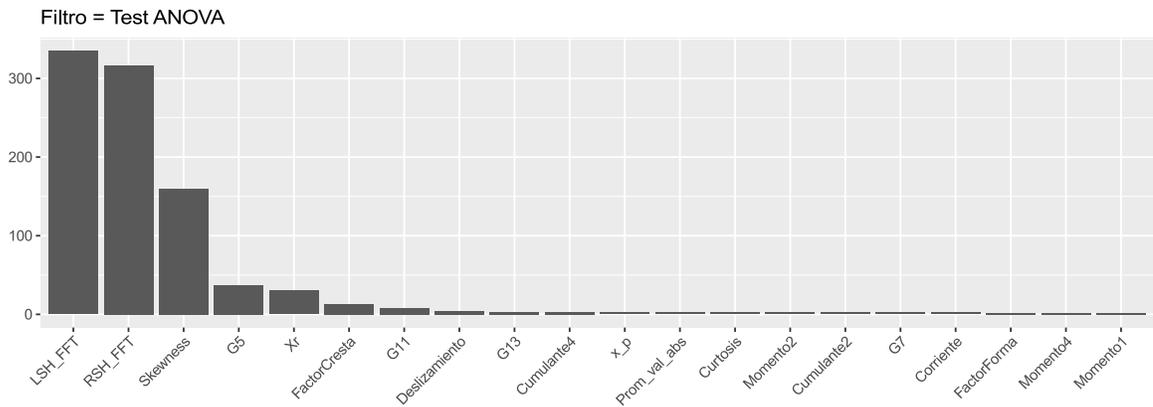
Resultados con alimentación de red.

En la Fig. 5.14 se presenta el ranking de las características obtenido con el método de la ganancia de información (GI), con la prueba ANOVA, así como con el algoritmo *Relief-F*. Teniendo en cuenta los resultados de la Fig. 5.14 y si se considera un umbral que reduzca del conjunto total de características a siete, las características del conjunto final serían las de la Tabla 5.2. Parece ser que las tres técnicas coinciden en que el LSH, el RSH, y la *Skewness* son indicadores bastante relevantes de la condición de un MI cuando se alimenta de red.

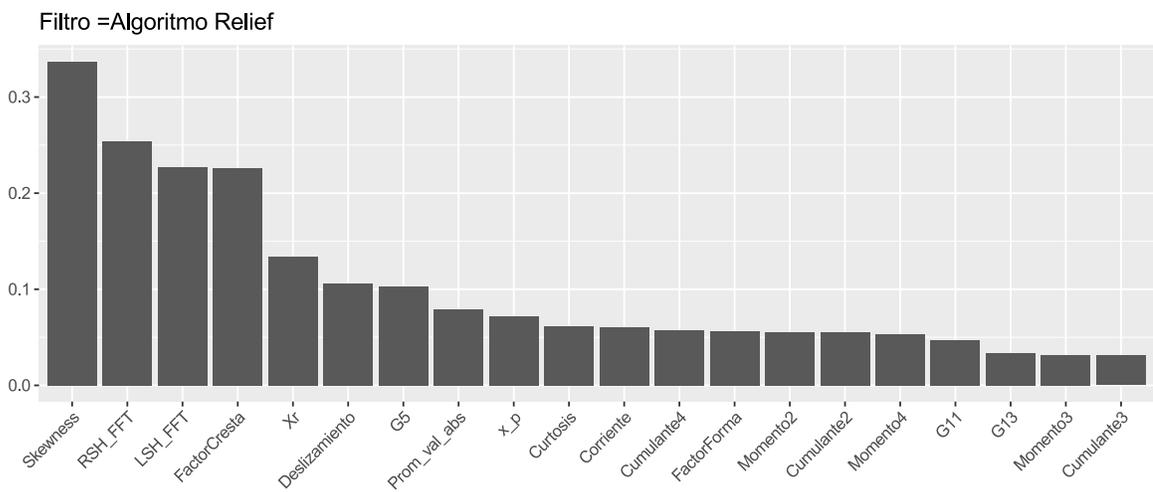
Lo más reseñable de la Tabla 5.2 es que cuando se analizan ambos niveles de carga a la vez el indicador Γ_5 resulta ser relevante. El resto de características aparecen en uno u otro caso.



(a) GI



(b) ANOVA



(c) Relief-F

Figura 5.14: Ordenamiento de las características con los métodos de filtrado en alimentación de red.

Alimentación de red			
Posición	NC1	NC2	Ambos NC
1	LSH	<i>Skewness</i>	RSH
2	RSH	RSH	LSH
3	Deslizamiento	LSH	Deslizamiento
4	x_p	Deslizamiento	<i>Skewness</i>
5	x_r	Factor cresta	Γ_5
6	Cumulante 4	x_r	x_r
7	Factor cresta	Prom. val. abs. ($ \bar{x} $)	Factor cresta

Tabla 5.2: Características más informativas según los métodos de filtrado (Umbral de 7 características). Alimentación de red.

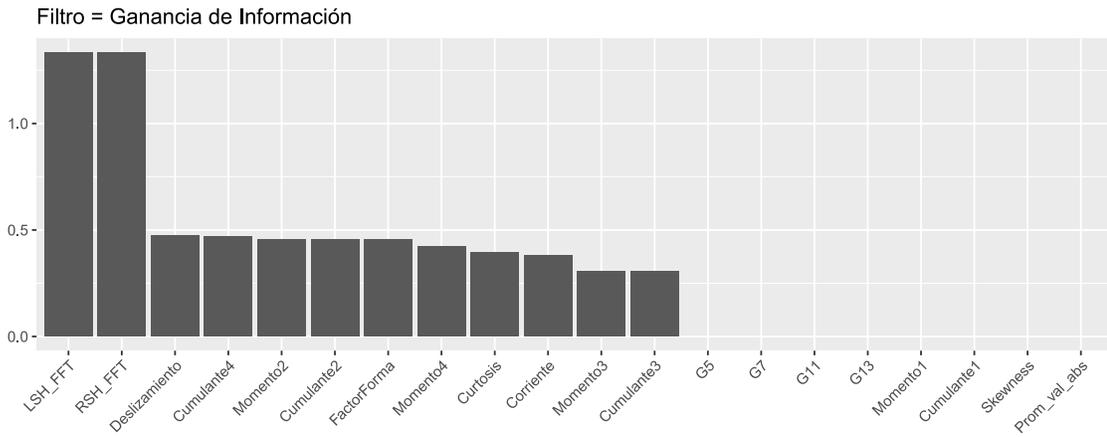
Resultados con el inversor ABB.

En la Fig. 5.15 se presenta el ranking de las características obtenido con los mismos métodos que el caso anterior pero para alimentación con inversor ABB.

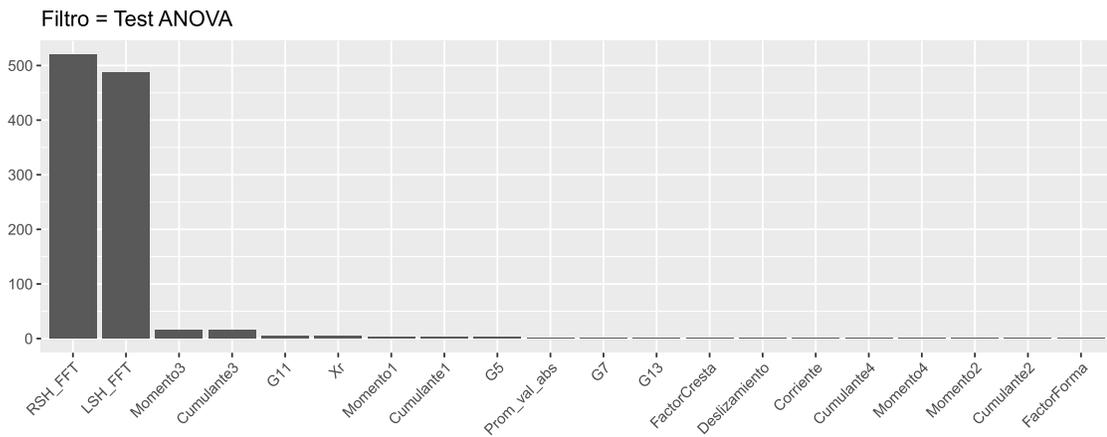
Teniendo en cuenta los resultados de la Fig. 5.15 y si se considera igualmente un umbral que reduzca el conjunto de características a siete, las características del conjunto final serían las de la Tabla 5.3. En este caso, las tres técnicas coinciden en que las variables diferentes al LSH y al RSH, no juegan un papel determinante para discriminar el estado del rotor con este tipo de alimentación.

Inversor ABB			
Posición	NC1	NC2	Ambos NC
1	RSH	RSH	RSH
2	LSH	LSH	LSH
3	Deslizamiento	Deslizamiento	Momento 3
4	RMS (Corriente)	Curtosis	Cumulante 3
5	Curtosis	Momento 4	x_r
6	Cumulante 4	Cumulante 4	Cumulante 4
7	Momento 4	Momento 2	Momento 2

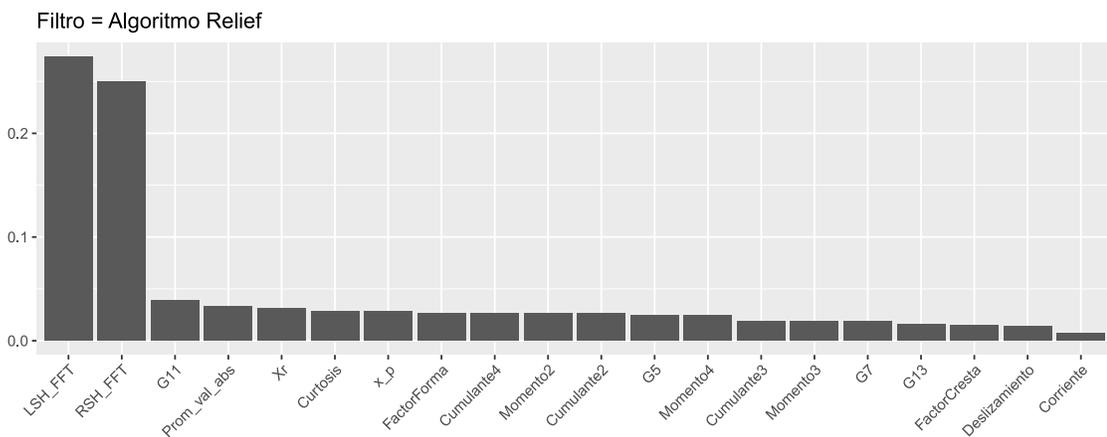
Tabla 5.3: Características más informativas según los métodos de filtrado (Umbral de 7 características). Inversor ABB.



(a) GI



(b) ANOVA

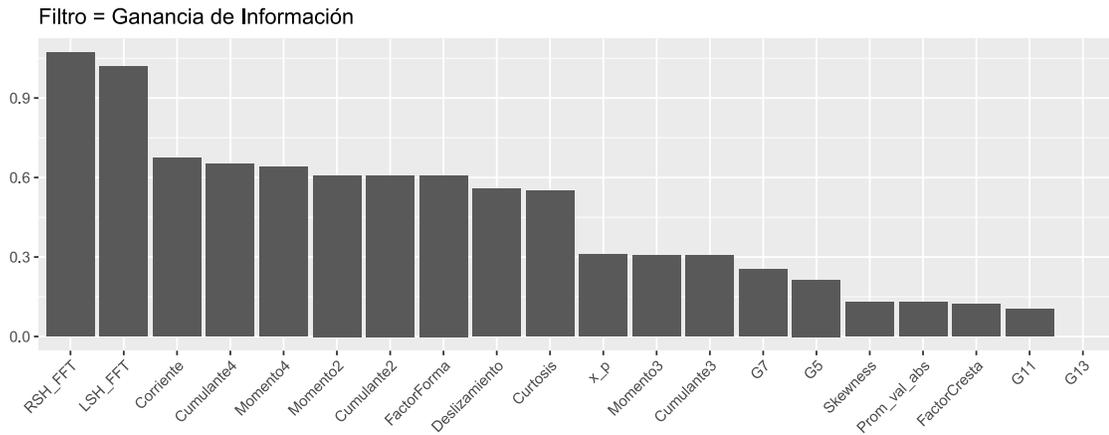


(c) Relief-F

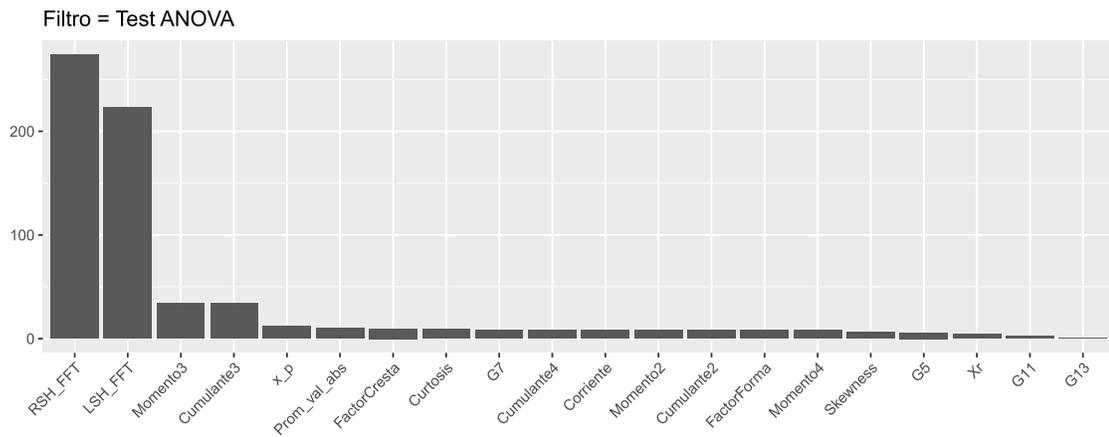
Figura 5.15: Ordenamiento de las características con los métodos de filtrado. Alimentación inversor ABB.

Resultados con el inversor Allen Bradley.

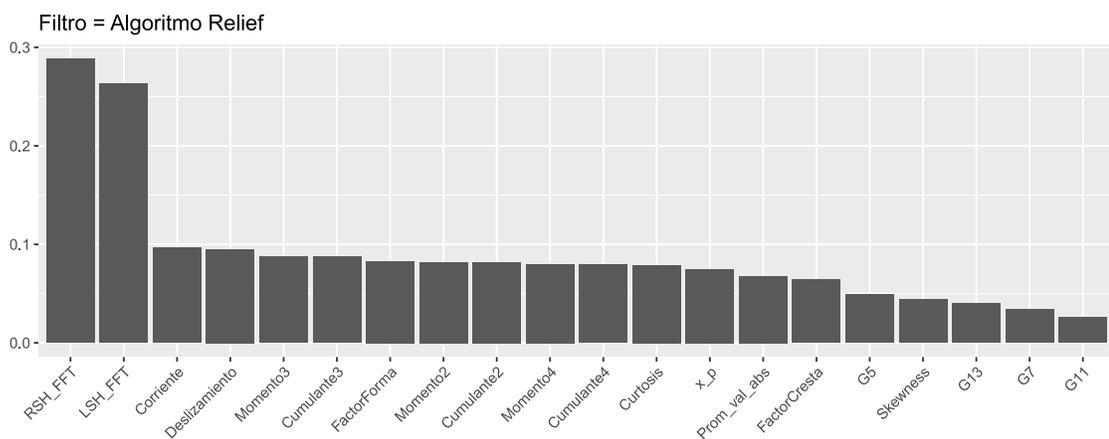
En la Fig. 5.16 se presenta el ranking de las características para el caso de alimentación con el inversor Allen Bradley.



(a) GI



(b) ANOVA



(c) Relief-F

Figura 5.16: Ordenamiento de las características con los métodos de filtrado. Alimentación inversor Allen Bradley.

Teniendo en cuenta los resultados de la Fig. 5.16 y si se considera igualmente un umbral que reduzca el conjunto de características a siete, las características del conjunto final serían las de la Tabla 5.4. Al igual que en caso del inversor ABB, las tres técnicas coinciden en que las variables diferentes al LSH y al RSH, no juegan un papel determinante para discriminar el estado del rotor. Sin embargo, para este tipo de alimentación las diferencias son más reducidas. El valor RMS de la corriente parece ser también relevante en este caso.

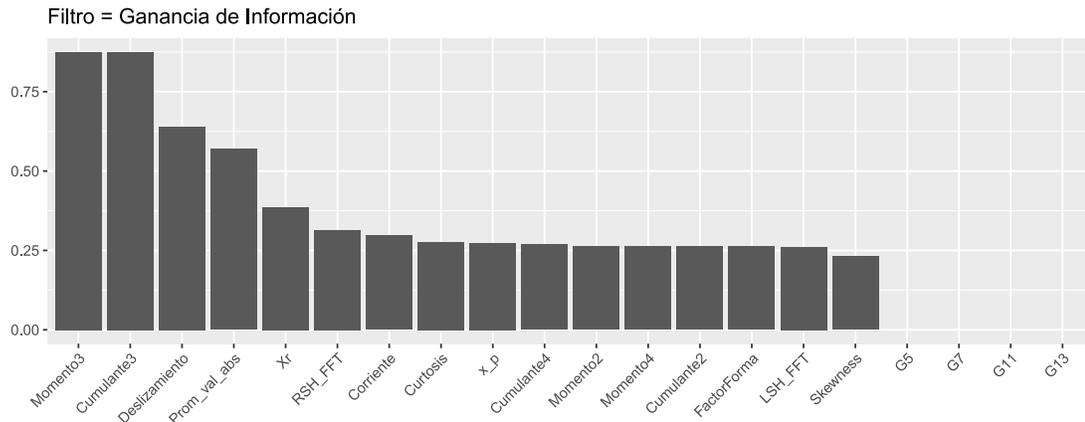
Inversor Allen Bradley			
Posición	NC1	NC2	Ambos NC
1	RSH	RSH	RSH
2	LSH	LSH	LSH
3	Deslizamiento	Factor Cresta	Momento 3
4	Γ_5	RMS (Corriente)	Cumulante 3
5	RMS (Corriente)	Momento 2	RMS (Corriente)
6	Momento 4	Cumulante 2	Momento 2
7	Cumulante 4	Factor forma	Γ_7

Tabla 5.4: Características más informativas según los métodos de filtrado (Umbral de 7 características). Inversor Allen Bradley.

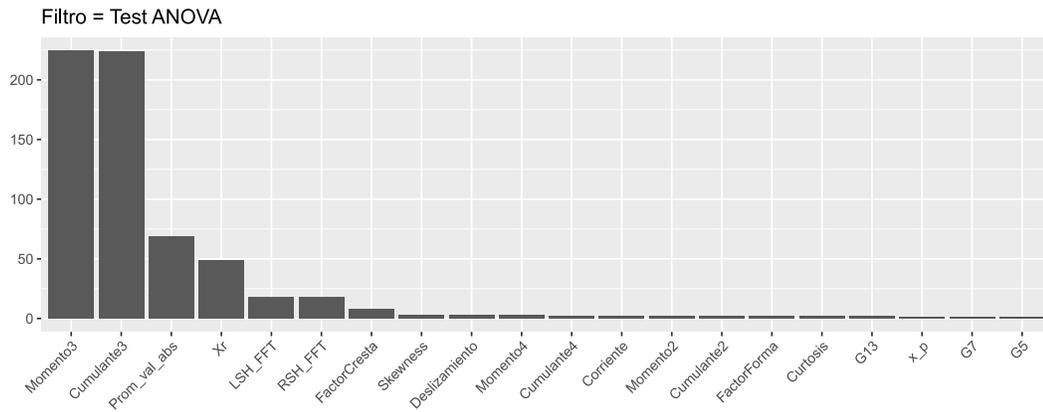
Al igual que se ha hecho anteriormente, los resultados de la Fig. 5.16 se resumen en la Tabla 5.4 a siete características.

Resultados con el inversor ruidoso (Telemecanique).

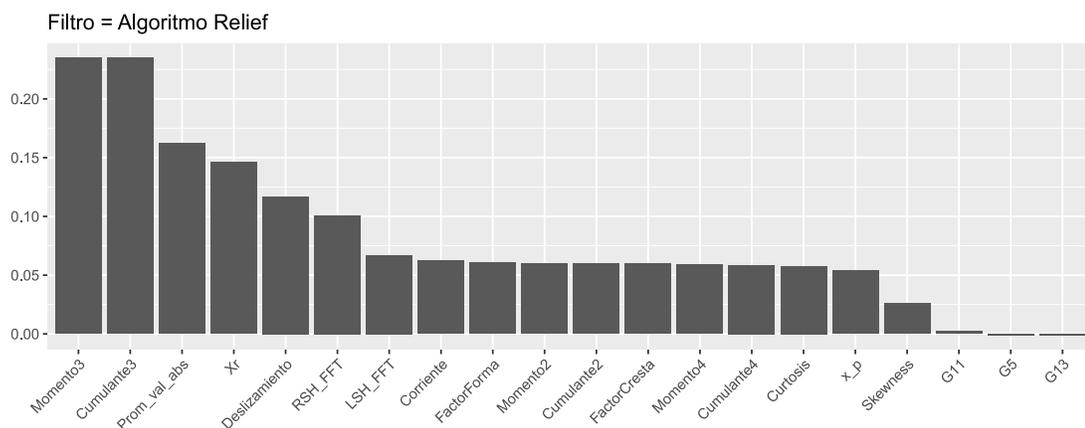
Finalmente, en la Fig. 5.17 se presenta el ranking de las características para el caso de alimentación con un inversor mucho más ruidoso como lo es el de Telemecanique.



(a) GI



(b) ANOVA



(c) Relief-F

Figura 5.17: Ordenamiento de las características con los métodos de filtrado. Alimentación inversor Telemecanique.

Inversor Telemecanique			
Posición	NC1	NC2	Ambos NC
1	Deslizamiento	Momento 3	Momento 3
2	Momento 3	Cumulante 3	Cumulante 3
3	Cumulante 3	RSH	Prom. val. abs. ($ \bar{x} $)
4	Prom. val. abs. ($ \bar{x} $)	Prom. val. abs. ($ \bar{x} $)	x_r
5	x_r	x_r	LSH
6	Factor cresta	RMS (Corriente)	RSH
7	RMS (Corriente)	Momento 2	RMS (Corriente)

Tabla 5.5: Características más informativas según los métodos de filtrado (Umbral de 7 características). Inversor Telemecanique.

Como se puede observar, los resultados bajo este tipo de fuente, son muy diferentes al de los otros inversores. Anteriormente, se observó que al tener un espectro ruidoso y con un nivel de cespced elevado, los valores de LSH y RSH no iban a ser muy relevantes en la discriminación de las diferentes severidades. Es más, observando los resultados de GI, ANOVA y del algoritmo *Relief-F* ninguno de esos indicadores está presente en las cuatro primeras posiciones. Sin embargo, se aprecia que el Momento 3, el Cumulante 3 y en menor medida el Promedio de valores absolutos ($|\bar{x}|$) son considerados como características relevantes por este tipo de métodos.

5.8.2. Resultados de la selección recursiva de características con *Random Forest*.

Aunque los métodos de filtrado sirven para indicar qué variables son más relevantes atendiendo a un criterio o métrica en particular, su uso está muy limitado para aplicaciones de aprendizaje supervisado ya que no tiene en cuenta las prestaciones de un clasificador.

A continuación, se presentan los resultados obtenidos con la técnica propuesta de selección recursiva de características a través de RF. La métrica empleada para evaluar las prestaciones del algoritmo es *Accuracy* y el método de estimación del error empleado en este caso es el de 5 repeticiones de 10-folds de validación cruzada. En este caso, la técnica se prueba de forma independiente para ambos niveles de carga.

Resultados con alimentación de red.

En la Fig. 5.18 se muestran los resultados de las prestaciones de la técnica para el caso de alimentación de red, en función del tamaño del conjunto de variables atendiendo cada una de las gráficas a un nivel de carga en particular. Se puede apreciar que para ambos casos el conjunto óptimo es de cuatro variables. En este caso, el rendimiento del algoritmo no sufre un excesivo deterioro con el aumento del conjunto de variables. Los resultados del orden de importancia de cada variable se muestran en la Tabla 5.6. Como se puede observar en la Tabla 5.6, los resultados de RF-RFE son coherentes con aquellos obtenidos con los métodos de filtrado.

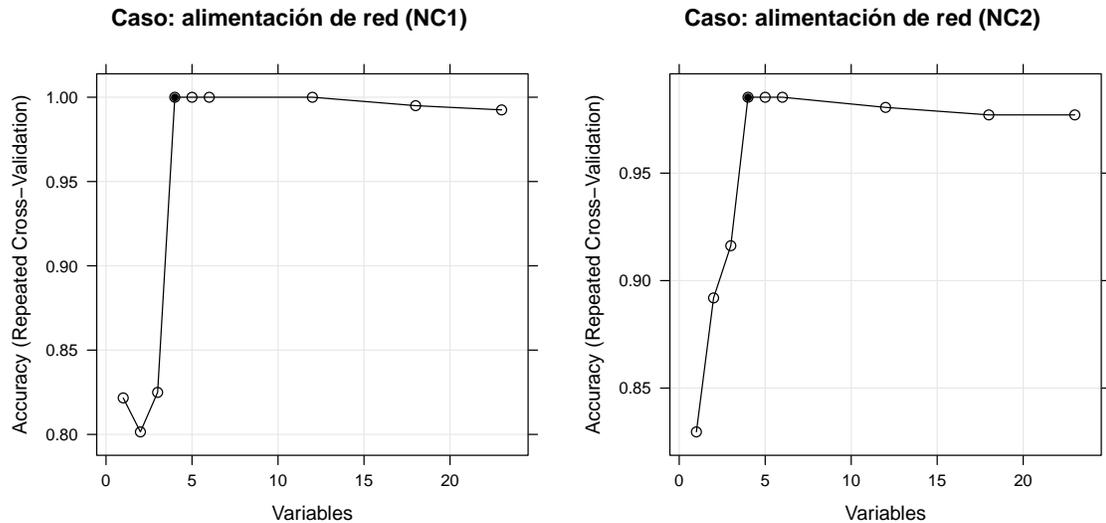


Figura 5.18: Tamaño del conjunto de características seleccionadas con RF-RFE (5-repeated 10-fold CV). Alimentación de red

Resultados con el inversor ABB.

En la Fig. 5.19 se muestran los resultados de las prestaciones de la técnica para el caso de alimentación con el inversor ABB, en función del tamaño del conjunto de variables al igual que en el caso anterior. En este caso, el conjunto óptimo es diferente según el nivel de carga considerado. Para los datos obtenidos con este tipo de fuente de alimentación, se puede ver que el rendimiento de RF-RFE se reduce drásticamente a medida que aumenta el número de variables. Los resultados del orden de importancia de cada variable se muestran en la

Alimentación de red		
Posición	NC1	NC2
1	LSH	RSH
2	RSH	Skewness
3	Deslizamiento	LSH
4	Factor Cresta	x_r

Tabla 5.6: Características seleccionadas con RF-RFE. Alimentación de red.

Tabla 5.7. Observando la Tabla 5.7, los resultados obtenidos con RF-RFE son similares a aquellos obtenidos con los métodos de filtrado anteriores.

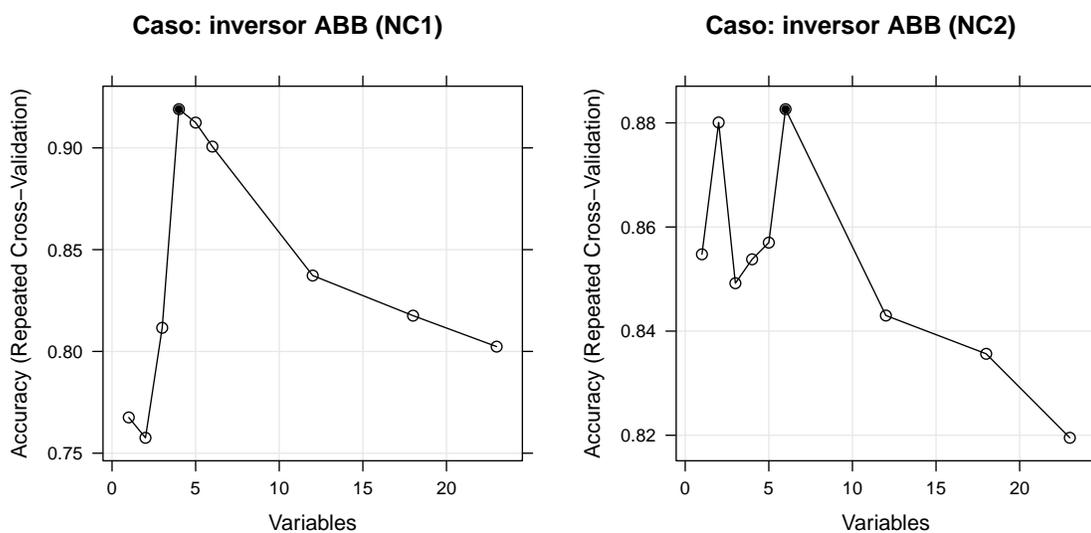


Figura 5.19: Tamaño del conjunto de características seleccionadas con RF-RFE (5-repeated 10-fold CV). Inversor ABB.

Resultados con el inversor Allen Bradley.

Para el caso de alimentación con el inversor Allen Bradley, los resultados se muestran en la Fig. 5.20. Parece ser que a diferencia de los casos anteriores, para este caso concreto las mejores prestaciones se consiguen con el conjunto completo de variables. Las variables

Inversor ABB		
Posición	NC1	NC2
1	LSH	LSH
2	RSH	RSH
3	Deslizamiento	Deslizamiento
4	Momento 4	Cumulante 3
5	-	Momento 3
6	-	x_p

Tabla 5.7: Características seleccionadas con RF-RFE. Inversor ABB.

seleccionadas se muestran en la Tabla 5.8. De la Tabla 5.8, se puede ver que los resultados obtenidos con RF-RFE difieren de cierta manera para las últimas características incluidas por la técnica respecto a los métodos de filtrado. Sin embargo, para este tipo de inversor, se puede ver que el rendimiento de RF-RFE va en incremento a medida que aumenta el número de variables.

Resultados con el inversor ruidoso (Telemecanique).

Para el caso de alimentación con el inversor Telemecanique, los resultados se muestran en la Fig. 5.21. A diferencia de los casos anteriores, para este tipo de inversor las mejores prestaciones se consiguen con un conjunto de 12 y 18 variables para los niveles de carga NC1 y NC2 respectivamente. Observando la Tabla 5.9, se puede ver que los resultados obtenidos con RF-RFE no difieren excesivamente de los obtenidos con los métodos de filtrado. Para NC1 el rendimiento de RF-RFE se mantiene aproximadamente constante para conjuntos de entre 6 y 23 variables. Sin embargo, para NC2 se puede ver que el rendimiento de RF-RFE sufre un ligero incremento a medida que aumenta el número de variables para conjuntos de entre 10 y 23. Las variables seleccionadas se muestran en la Tabla 5.9.

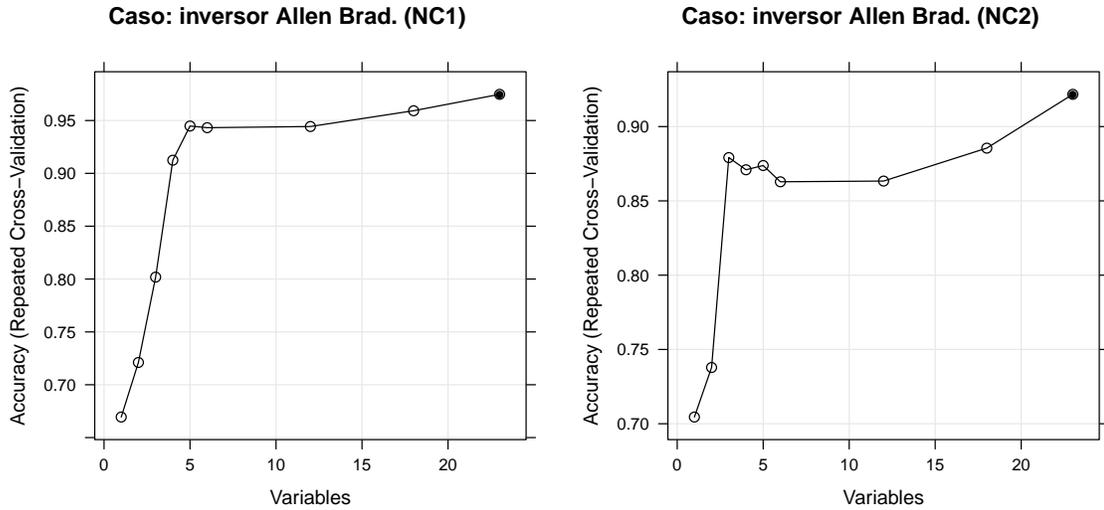


Figura 5.20: Tamaño del conjunto de características seleccionadas con RF-RFE (5-repeated 10-fold CV). Inversor Allen Bradley.

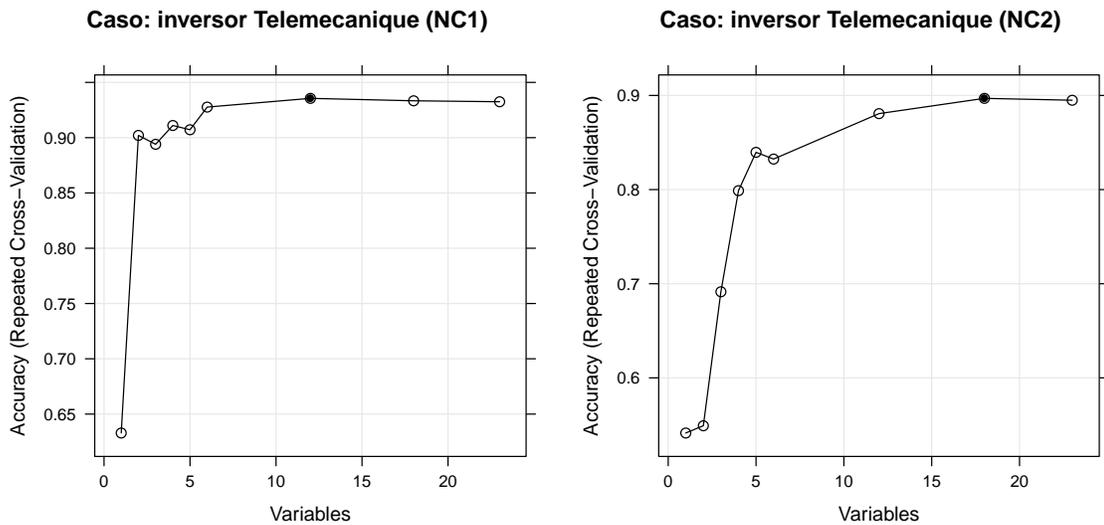


Figura 5.21: Tamaño del conjunto de características seleccionadas con RF-RFE (5-repeated CV). Inversor Telemecanique.

Inversor Allen Bradley		
Posición	NC1	NC2
1	RSH	RSH
2	LSH	LSH
3	Γ_5	Momento 4
4	Deslizamiento	Corriente (RMS)
5	Corriente (RMS)	Momento 2
6	Momento 4	Factor Forma
7	Momento 2	Cumulante 2
8	Cumulante2	Factor Cresta
9	Cumulante 4	Momento 3
10	Factor Forma	Cumulante 4
11	Curtosis	Cumulante 3
12	Momento 3	Γ_{11}
13	Cumulante 3	Curtosis
14	Γ_{11}	Deslizamiento
15	Factor Cresta	x_p
16	x_p	Γ_{13}
17	Γ_7	Γ_5
18	Γ_{13}	Prom val abs ($ \bar{x} $)
19	Prom val abs ($ \bar{x} $)	Γ_7
20	X_r	X_r
21	Skewness	Skewness
22	Momento 1	Momento 1
23	Cumulante 1	Cumulante 1

Tabla 5.8: Características seleccionadas con RF-RFE. Inversor Allen Bradley.

Inversor Telemecanique		
Posición	NC1	NC2
1	Deslizamiento	Cumulante 3
2	Momento 3	Momento 3
3	Cumulante 3	Prom. val. abs. ($ \bar{x} $)
4	Prom val abs ($ \bar{x} $)	RSH
5	X_r	X_r
6	Factor Cresta	LSH
7	Skewness	Deslizamiento
8	Corriente (RMS)	Corriente (RMS)
9	x_p	Cumulante 4
10	LSH	Factor Forma
11	Curtosis	Momento 2
12	Momento4	Cumulante 2
13	-	Momento 4
14	-	Curtosis
15	-	x_p
16	-	Skewness
17	-	Momento 1
18	-	Factor Cresta

Tabla 5.9: Características seleccionadas con RF-RFE. Inversor Telemecanique.

5.9. Resultados de la herramienta de diagnóstico.

En esta parte del capítulo se muestran tanto los resultados de aplicar la técnica SMOTE para obtener conjuntos de datos de entrenamiento equilibrados como aquellos resultados tras aplicar el algoritmo *AdaBoost* a un conjunto de datos de test no empleados anteriormente. Además, se compararán los resultados de *AdaBoost* con otros algoritmos usados en la literatura como Naive-Bayes, k -NN, SVM con *kernel* de funciones de base radial así como con la técnica de *Bagging*.

5.9.1. Resultados de equilibrar los datos de entrenamiento con SMOTE.

Para hacer un estudio de cómo afectan los conjuntos de datos desequilibrados en las técnicas de diagnóstico automático de fallos en MI, se realizan pruebas atendiendo a varios grados de desequilibrio ($IR = 10$, $IR = 5$ e $IR = 2$). Como era de esperar y como así ha sido, unas de las variables más importantes para la mayoría de los casos han sido el LSH y el RSH. En este apartado se presentan los resultados de la generación sintética de observaciones para los características LSH y RSH en función del deslizamiento.

A continuación, se muestran los resultados de aplicar SMOTE a los datos obtenidos con todas las fuentes de alimentación. Para el caso de $IR = 10$ el número de vecinos más cercanos para la generación sintética de observaciones es de $k = 1$, y para el caso de $IR = 5$ el número de vecinos más cercanos es de $k = 3$. Los estados del rotor se representan de la siguiente manera: motor sano (1), rotor con fallo de barra de severidad R2 (2), rotor con fallo de barra de severidad R3 (3), rotor con fallo de barra de severidad (4), rotor con una barra completamente rota R5 (5).

Caso de alimentación de red.

En la parte superior de la Fig. 5.22 se muestran las observaciones para el caso desequilibrado con un $IR = 10$. Se puede ver cómo los valores de RSH de las pruebas de motor sano están más dispersos que para el LSH. En las figuras de la parte inferior se muestran los resultados del equilibrado del conjunto de datos anterior tras aplicar SMOTE.

Por otro lado, en la parte superior de la Fig. 5.23 se muestran las observaciones para el caso desequilibrado con un $IR = 5$. En la parte inferior de la Fig. 5.23 se muestran los resultados del equilibrado del conjunto de datos anterior tras aplicar SMOTE. En este caso, al haber más observaciones de la clase de fallo, la forma de poblar las regiones de las clases de fallo es diferente. Esto motivará al clasificador a construir la ensamble de clasificadores débiles de manera diferente.

Caso de alimentación con el inversor ABB.

En la Fig. 5.24 se muestran las mismas figuras que en el caso anterior para el caso desequilibrado con un $IR = 10$ y alimentación con el inversor ABB.

Por otro lado, en la Fig. 5.25 se muestran los resultados de las pruebas con el inversor ABB para el caso desequilibrado con $IR = 5$. En las figuras de la parte inferior se muestran los resultados del equilibrado del conjunto de datos anterior tras aplicar SMOTE. Con los

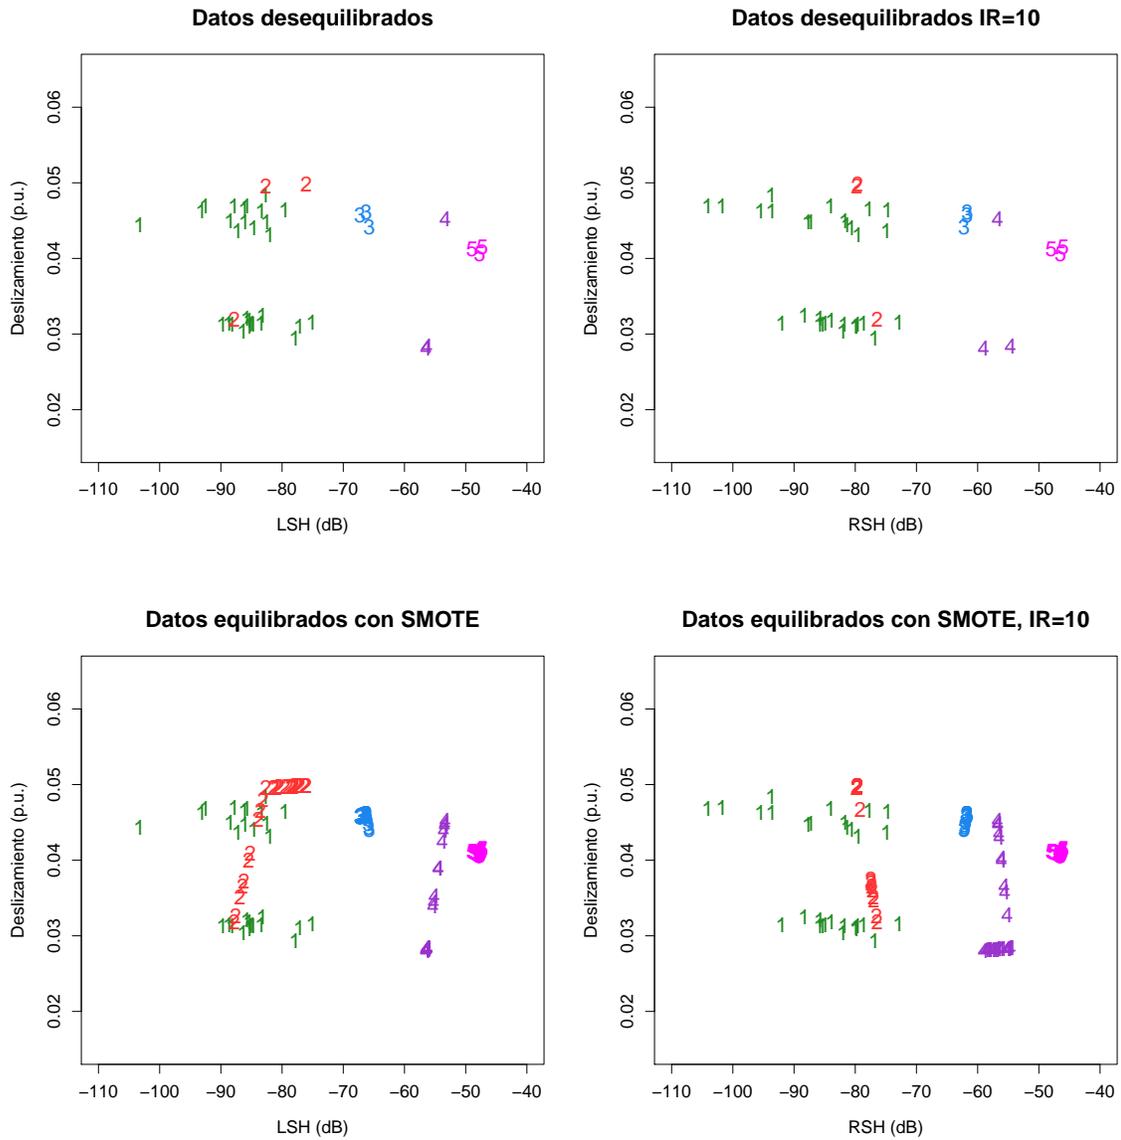


Figura 5.22: Aplicación de SMOTE para $IR = 10$. Se muestra el LSH y RSH para alimentación de red.

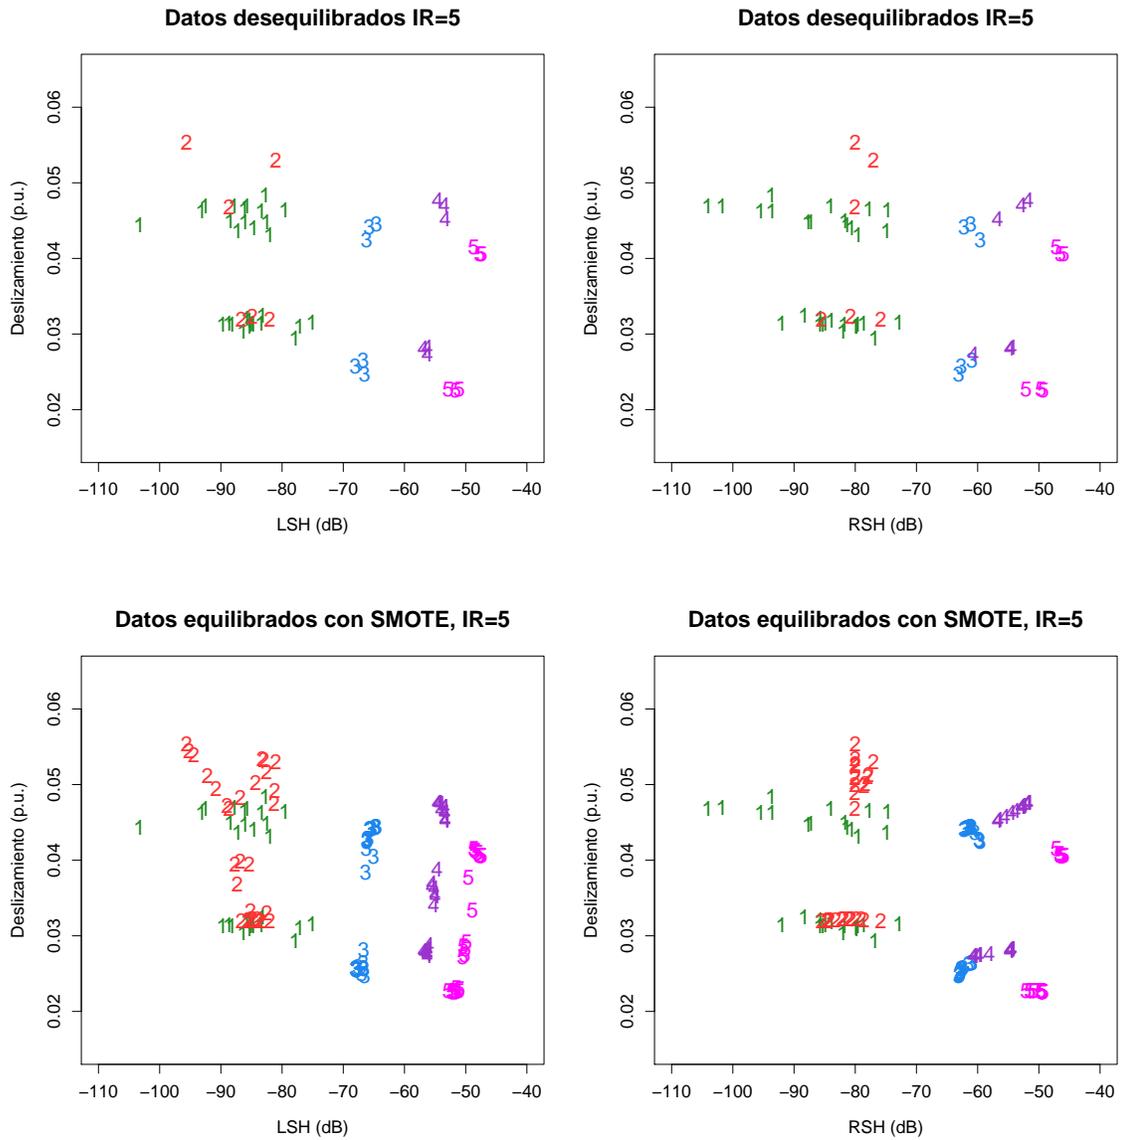


Figura 5.23: Aplicación de SMOTE para $IR = 5$. Se muestra el LSH y RSH para alimentación de red.

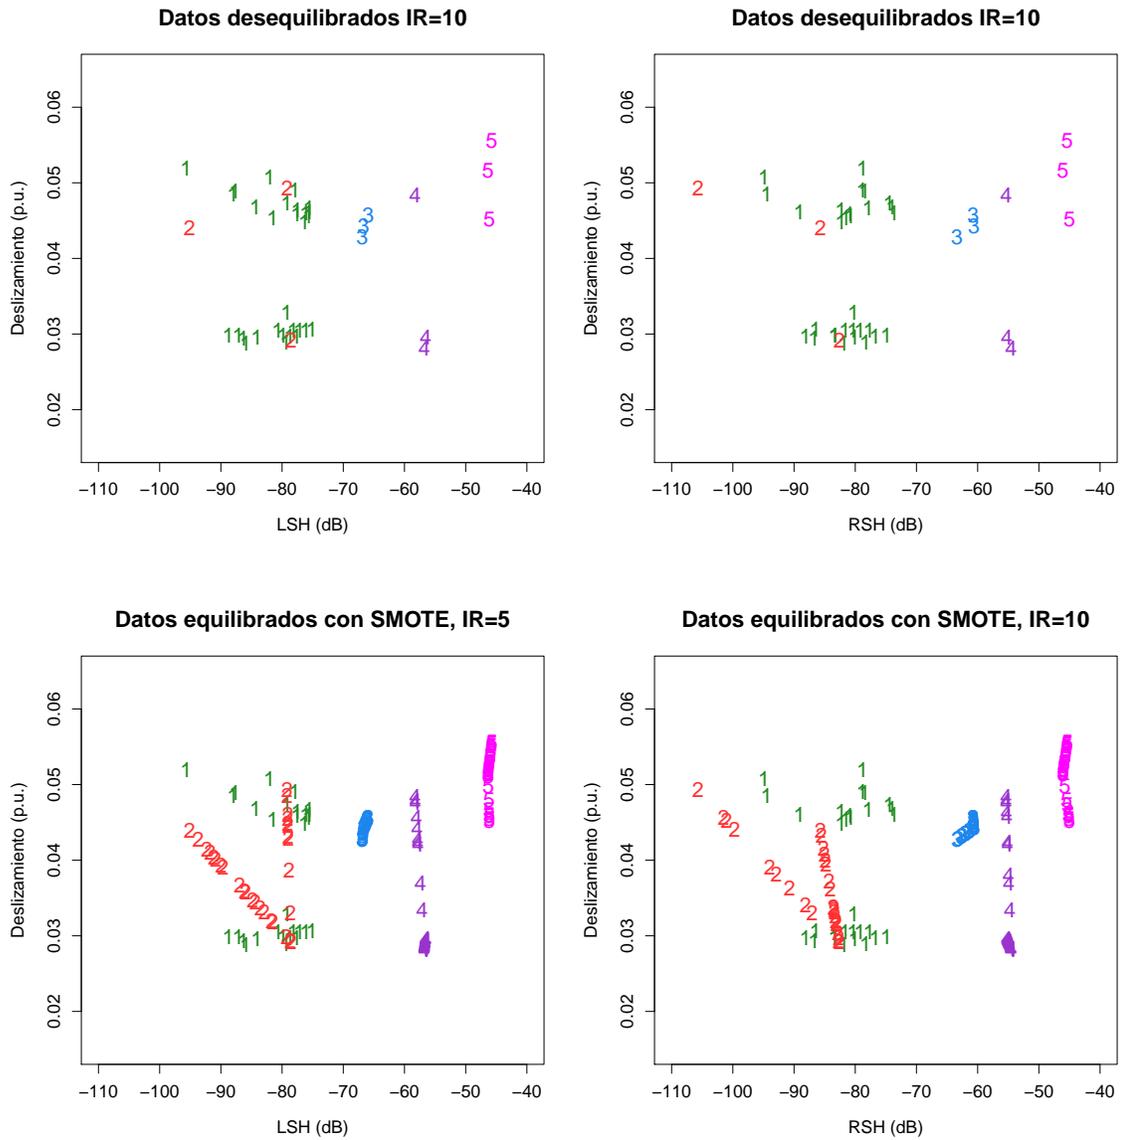


Figura 5.24: Aplicación de SMOTE para $IR = 10$. Se muestra el LSH y RSH para alimentación por inversor ABB.

datos de este inversor, se puede ver que las clases R3, R4 y R5 siguen siendo perfectamente separables tras aplicar la técnica SMOTE.

Caso de alimentación con el inversor Allen Bradley.

En la Fig. 5.26 se muestran las observaciones para el caso desequilibrado con un $IR = 10$ con el inversor Allen Bradley.

En la Fig. 5.27 se muestran las observaciones para el caso desequilibrado con $IR = 5$. En la parte inferior se muestran los resultados del equilibrado del conjunto de datos anterior tras aplicar SMOTE. Para este inversor, no se puede ver una clara separación entre las clases R1, R2 y R3. Sin embargo, R4 y R5 siguen siendo perfectamente separables tras aplicar la técnica SMOTE.

Caso de alimentación con el inversor Telemecanique.

En la Fig. 5.28 se muestran las observaciones para el caso desequilibrado con un $IR = 10$ para el inversor de Telemecanique. Se ha de recordar, que para este tipo de alimentación existían otras variables más relevantes por encima del LSH y del RSH como el Momento 3 y Cumulante 3. Por lo tanto, es de esperar que el diagrama de dispersión al equilibrar los datos con SMOTE sea más desfavorable que en los casos anteriores.

En la Fig. 5.29 se muestran las observaciones para el caso desequilibrado con un $IR = 5$. De igual manera que en casos anteriores se muestran los resultados tras aplicar SMOTE en la parte inferior. En la parte inferior, tanto de la Fig. 5.28 como de la Fig. 5.29 se puede apreciar que, considerando el LSH y el RSH en función del deslizamiento, no hay una clara separación entre severidades. Esto confirma que las características de LSH y RSH no son tan significativas para diagnosticar el motor ante este tipo de alimentación respecto a los casos anteriores.

5.9.2. Resultados de *AdaBoost* con datos conjuntos de fuentes de alimentación.

En los siguientes apartados se presentan los resultados de *AdaBoost* para diferentes casos de estudio. En la Tabla 5.10 se describen los conjuntos de datos empleados. Para este estudio se emplean conjuntos de datos tanto de alimentación de red como con el inversor ABB.

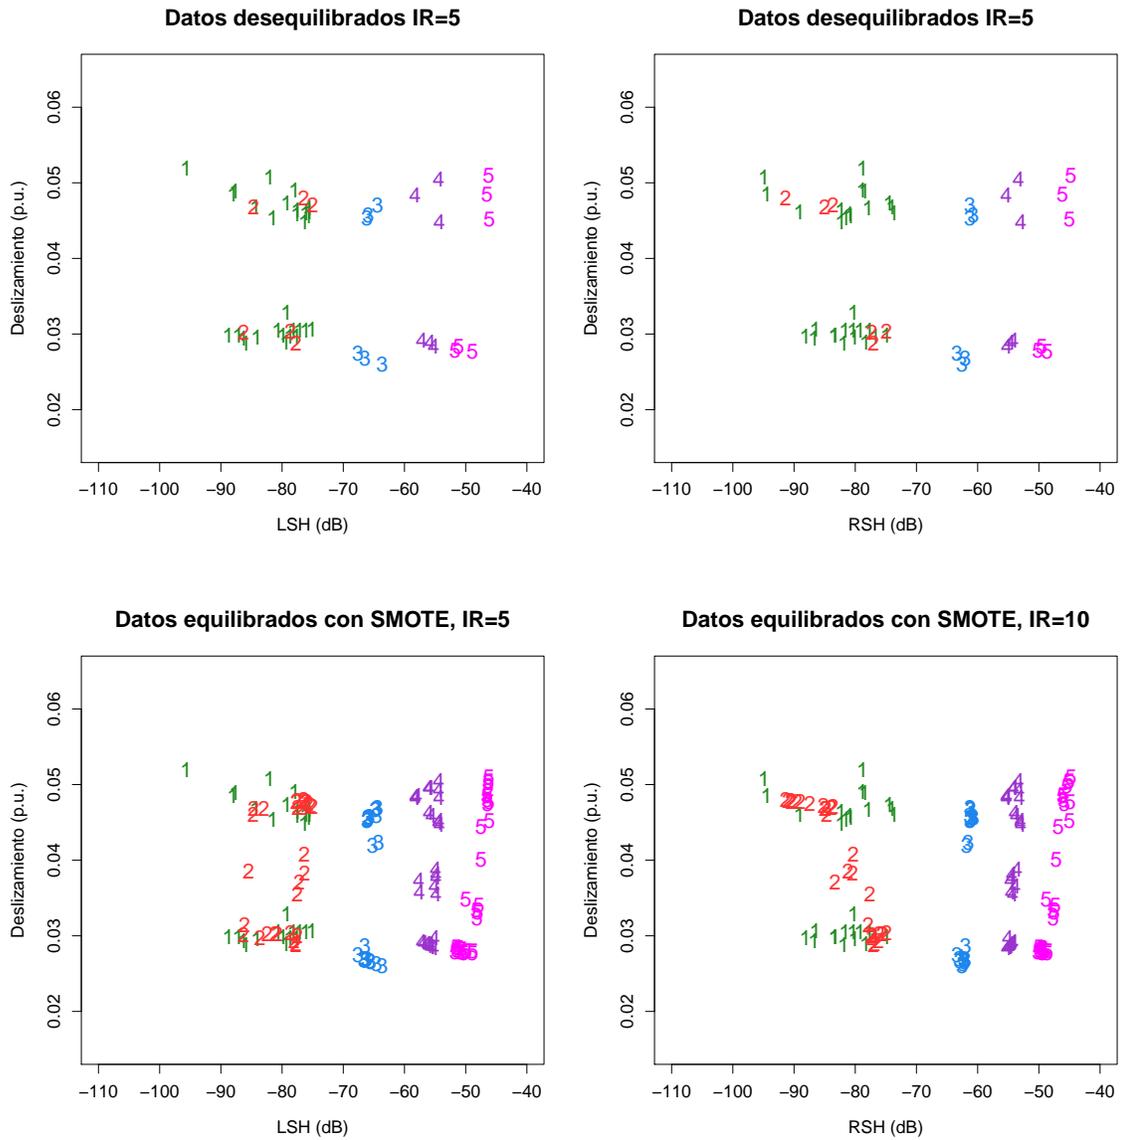


Figura 5.25: Aplicación de SMOTE para $IR = 5$. Se muestra el LSH y RSH para alimentación por inversor ABB.

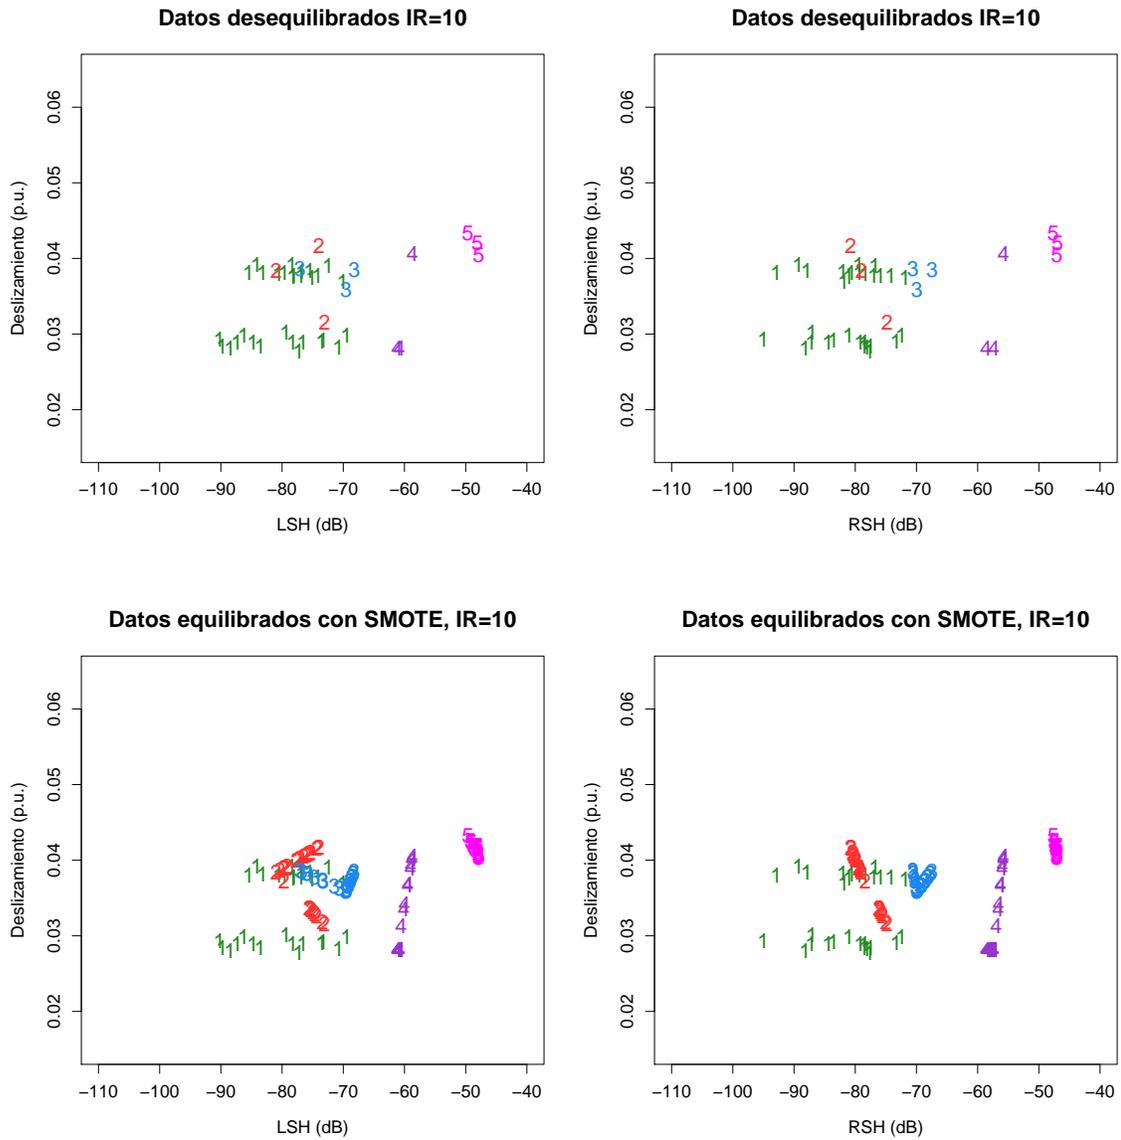


Figura 5.26: Aplicación de SMOTE para IR=10. Se muestra el LSH y RSH para alimentación por inversor Allen Brad.

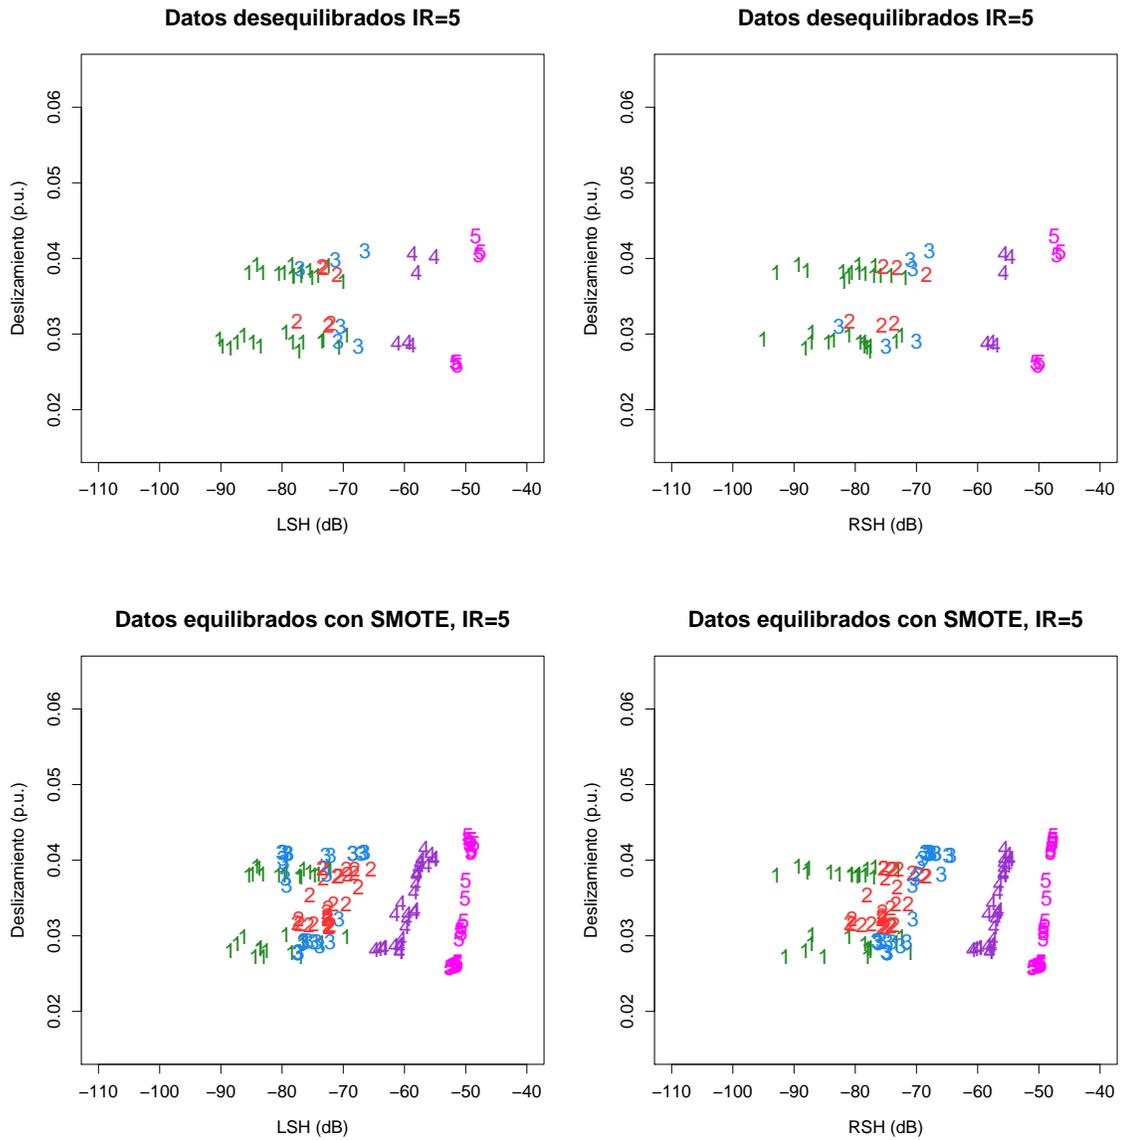


Figura 5.27: Aplicación de SMOTE para $IR = 5$. Se muestra el LSH y RSH para alimentación por inversor Allen Brad.

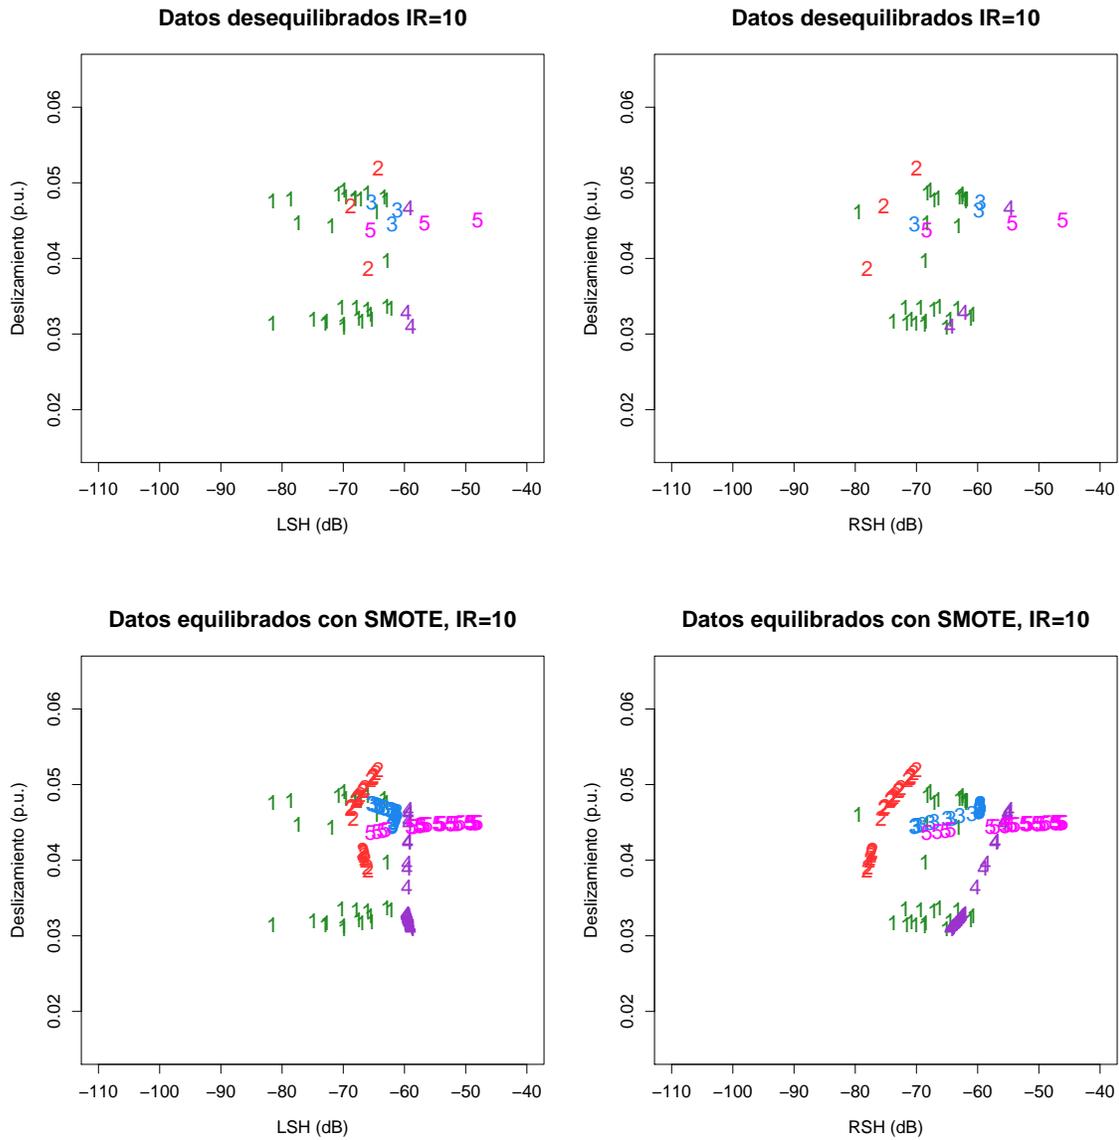


Figura 5.28: Aplicación de SMOTE para $IR = 10$. Se muestra el LSH y RSH para alimentación por inversor Telemecanique.

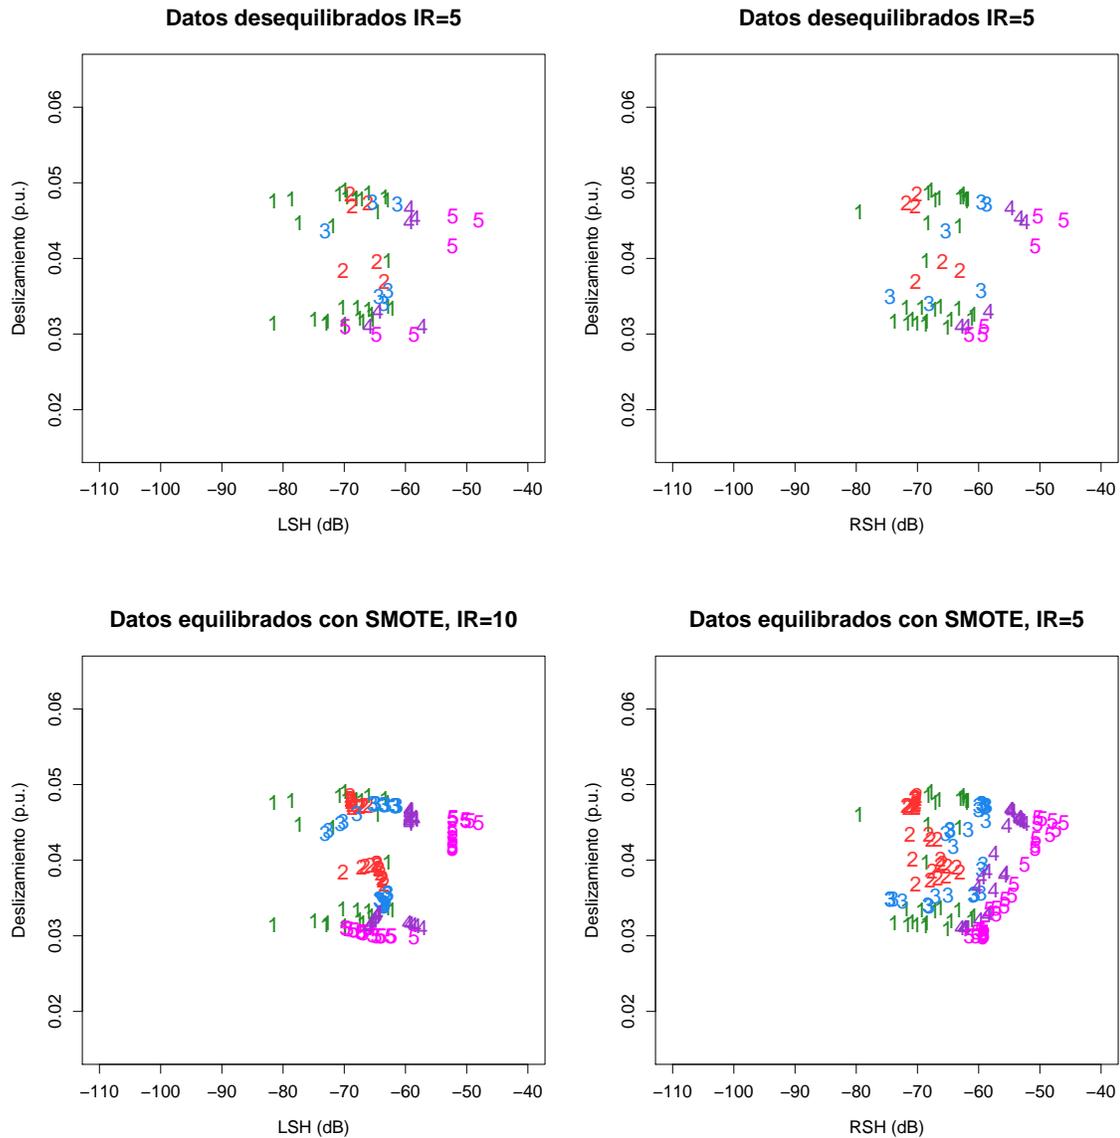


Figura 5.29: Aplicación de SMOTE para $IR = 5$. Se muestra el LSH y RSH para alimentación por inversor Telemecanique.

Estado del Rotor	IR	Número de observaciones (ABB y RED)
R1	1; 2; 5; 10	60 (IR=1),120 resto
R2	1; 2; 5; 10	60; 60; 24; 12
R3	1; 2; 5; 10	60; 60, 24; 12
R4	1; 2; 5; 10	60; 60; 24; 12
R5	1; 2; 5; 10	60; 60; 24; 12

Tabla 5.10: Descripción de los conjuntos de datos.

5.9.2.1. Resultados de *AdaBoost* con clasificación multiclase.

En este apartado, se considera un enfoque de clasificación multiclase, donde el clasificador es entrenado con observaciones de todas las clases (de R1 a R5) por medio de un procedimiento de validación cruzada con 5 repeticiones. El conjunto de datos analizado está constituido con observaciones del caso de alimentación de red e inversor ABB. Mediante SMOTE, la distribución original de las clases se altera para generar las observaciones sintéticas adicionales de la forma descrita anteriormente. Con esta técnica de equilibrado, se ha observado un aumento en el número de casos de fallo correctamente clasificados, como se puede observar en la Tabla 5.11. La Tabla 5.11 muestra la MC (en porcentaje) y sus métricas derivadas para el clasificador *AdaBoost* sin aplicar SMOTE y aplicando SMOTE para un $IR = 2$, separados por puntos y coma, respectivamente. Las métricas *Recall* y *Precision* se usan para analizar el desempeño de la clasificación sobre las observaciones de fallo. En el primer caso (*AdaBoost* sin aplicar SMOTE) se encuentran resultados más pobres para el grado de severidad R2. Sin embargo, cuando se utiliza el algoritmo SMOTE para obtener un conjunto equilibrado, el rendimiento del clasificador mejora cuantitativamente con respecto a esta severidad de fallo del rotor (R2).

5.9.2.2. Resultados de clasificación biclase con *AdaBoost* para diferentes IR.

Dado que existen varios algoritmos de ML usados como herramientas de diagnóstico de MI, es necesario comparar el clasificador *AdaBoost* con algunos de ellos. En este apartado, se presenta una comparación de *AdaBoost* con otros algoritmos como Naive Bayes (NB), y los Árboles de decisión (DT) con el algoritmo *Classification And Regression Trees* (CART) usando un enfoque “*One Against One*” (OAO). En este estudio, se han tenido en cuenta algunas de las métricas de desempeño descritas en el Capítulo 3. Recordamos que en este caso,

Estado Rotor Predicho (%)	Estado Rotor Real (%)				
	R1	R2	R3	R4	R5
R1	30.3; 16.9	4.2; 3.3	0.0; 0.0	0.7; 0.8	0.0; 0.0
R2	2.7; 2.5	12.5; 16.7	0.3; 0.3	0.0; 0.1	0.0; 0.0
R3	0.3; 0.1	0.0; 0.0	16.3; 19.7	0.0; 0.0	0.0; 0.0
R4	0.0; 0.2	0.0; 0.0	0.00; 0.00	15.9; 19.1	0.4; 0.3
R5	0.0; 0.0	0.0; 0.0	0.0; 0.0	0.0; 0.0	16.3; 19.7
Métricas por clase					
Recall	0.91; 0.86	0.75; 0.83	0.98; 0.98	0.96; 0.95	0.98; 0.98
Precision	0.86; 0.80	0.81; 0.85	0.98; 0.99	0.97; 0.97	1.00; 1.00

Tabla 5.11: MC (%) y métricas de *AdaBoost* para el caso multiclase con SMOTE ($IR = 2$) y sin SMOTE.

los parámetros de ajuste han sido fijados atendiendo a un procedimiento de 5 repeticiones de validación cruzada. Para proporcionar una explicación detallada (pero no excesivamente extensa) del comportamiento de los clasificadores, se presenta una comparación individual para las severidades del rotor R2 y R3 en las Tablas 5.12 y 5.13 respecto a la clase sano. En la Tabla 5.12 se presentan las métricas de desempeño para el problema desequilibrado sin aplicar SMOTE con los tres clasificadores bajo diferente IR. Al analizar el caso R2, *AdaBoost* muestra un mejor rendimiento en comparación con el resto. Sin embargo, a medida que el IR aumenta, sus resultados resultan más pobres. Este resultado se aplica igualmente a los otros dos clasificadores. También es interesante analizar los valores de *Accuracy* y observar cuán engañoso puede ser esta métrica. Los resultados de la clasificación con NB para un $IR = 10$ son un buen ejemplo ya que no hay una sola observación de R2 correctamente clasificada (valor de cero para las métricas *Precision* y *Recall*). Por otro lado, la clasificación en R3 consigue mejores resultados. En particular, *AdaBoost* alcanza valores destacables de *Precision* y *Recall*. Finalmente, con un $IR = 2$, que no es tan severo, se muestran resultados claramente más optimistas para cada clasificador tal y como se esperaba. Estos valores son más pequeños para R2 debido a la dificultad para obtener diferencias discriminatorias con la información del predictor respecto de la clase sano. La Tabla 5.13 muestra los resultados de la clasificación después de aplicar la técnica SMOTE. El desempeño parece mejorado considerablemente para cada clasificador. Sin embargo, parece que un IR alto ($= 10$) corregido con SMOTE,

mejora los resultados de los clasificadores NB y CART para la severidad R2. Sin embargo, los resultados de *AdaBoost* no varían demasiado. En cuanto a la gravedad de fallo R3, mientras que *AdaBoost* clasifica correctamente todas las observaciones pertenecientes a esta clase, NB y DT (CART) producen resultados peores a medida que el IR aumenta de 5 a 10.

Estado Rotor	IR	Clasificador	Accuracy	Precision	Recall
R2	10	NB	0.8091	0.0000	0.0000
		DT (CART)	0.9076	0.3333	0.0167
		AdaBoost	0.9561	1	0.5167
	5	NB	0.7681	0.2762	0.2417
		DT (CART)	0.8472	0.5472	0.4833
		AdaBoost	0.9514	0.9885	0.7167
	2	NB	0.6078	0.3801	0.28
		DT (CART)	0.8167	0.7491	0.6767
		AdaBoost	0.9811	0.9863	0.9567
R3	10	NB	0.947	0.6923	0.75
		DT (CART)	0.9712	0.8475	0.8333
		AdaBoost	0.9864	1	0.85
	5	NB	0.9194	0.6987	0.9083
		DT (CART)	0.975	0.9554	0.8917
		AdaBoost	0.9917	1	0.95
	2	NB	0.9078	0.8182	0.93
		DT (CART)	0.9433	0.9136	0.9167
		AdaBoost	0.9989	1	0.9967

Tabla 5.12: Métricas de performance para el caso desequilibrado sin aplicar SMOTE. Conjuntos de datos de tamaño: (120/12), (120/24) y (120/60) para $IR = 10$, $IR = 5$ e $IR = 2$ respectivamente.

5.9.2.3. Estudio para conjuntos de datos de diferentes tamaños.

A continuación, se realiza un análisis (Tabla 5.14), que trata de estudiar el efecto en el rendimiento de clasificación del tamaño del conjunto de datos de acuerdo con cada IR. Para ello, y por brevedad, sólo se considera la severidad de R2. Los resultados de *AdaBoost* sufren

Estado Rotor	IR	Clasificador	Accuracy	Precision	Recall
R2	10	NB	0.715	0.6949	0.7667
		DT (CART)	0.9208	0.9014	0.945
		AdaBoost	0.9967	0.9934	1
	5	NB	0.6483	0.644	0.6633
		DT (CART)	0.8642	0.8519	0.8817
		AdaBoost	0.9975	0.995	1
R3	10	NB	0.9233	0.9364	0.9083
		DT (CART)	0.955	0.9723	0.9367
		AdaBoost	1	1	1
	5	NB	0.9442	0.954	0.9333
		DT (CART)	0.9508	0.964	0.9367
		AdaBoost	1	1	1

Tabla 5.13: Métricas de performance para el caso equilibrado con SMOTE. Conjuntos de datos de tamaño: (120/12) y (120/24) para $IR = 10$ e $IR = 5$ respectivamente.

ligeras diferencias para las métricas presentadas para cada tamaño de conjunto de datos. Sin embargo, parece que *a priori* el tamaño del conjunto de datos no es determinante para asegurar buenos resultados para el mismo IR. La reducción de observaciones para obtener conjuntos de datos más pequeños se hace de forma aleatoria. Por esta razón, los resultados del rendimiento del clasificador están influenciados por los casos más complicados de clasificar y dependen posiblemente de su presencia en el conjunto final de prueba. Sin embargo, *AdaBoost* no está tan negativamente afectado, a diferencia de los clasificadores NB y DT, como demuestran sus evaluaciones de rendimiento. Se ha observado que sus puntuaciones varían en un pequeño rango sin un patrón identificado.

Finalmente, se presentan los resultados de reducir a un problema biclase (R1 frente al resto de severidades) con el enfoque OAA. Para este análisis, las curvas ROC son una de las medidas de rendimiento más recurrentes debido a la información gráfica que se puede obtener sobre el comportamiento del clasificador tal y como se vió en el Capítulo 3. En este caso, se utiliza un conjunto de datos tras aplicar SMOTE con un IR de 10. Las diferentes curvas ROC se muestran para cada clasificador en la Fig. 5.30. *AdaBoost* parece tener un mejor rendimiento respecto al resto ya que su curva ROC se muestra más cerca del punto óptimo

Estado Rotor	IR	Tamaño (S/F)	Clasificador	Precision	Recall
R2	10	120/12	NB	0.6949	0.7667
			DT (CART)	0.9014	0.945
			AdaBoost	0.9934	1
	60/6	NB	0.8328	0.8967	
		DT (CART)	0.8036	0.8867	
		AdaBoost	0.9967	0.9967	
	30/3	NB	1	1	
		DT (CART)	0.9571	0.8933	
		AdaBoost	1	1	
5	120/24	NB	0.644	0.6633	
		DT (CART)	0.8519	0.8817	
		AdaBoost	0.995	1	
	60/12	NB	0.6174	0.71	
		DT (CART)	0.8797	0.9267	
		AdaBoost	1	0.9967	
	30/6	NB	0.9184	0.9	
		DT (CART)	0.9032	0.9333	
		AdaBoost	1	0.9867	

Tabla 5.14: Métricas de performance para datos equilibrados con SMOTE para conjuntos de diferentes tamaños.

del espacio ROC. Es obvio que todas las curvas son diferentes y que el algoritmo *AdaBoost* supera al resto. Nótese cómo cada clasificador se comporta en un contexto genérico donde las observaciones de fallo se consideran igualmente importantes. Sin embargo, el análisis de OAO demostró las diferencias al discriminar entre varias severidades del rotor.

5.9.3. Comparación de *AdaBoost* con otros clasificadores en clasificación biclase.

En el apartado anterior se ha comparado la técnica para tres casos de desequilibrio ($IR = 2$, $IR = 5$ e $IR = 10$) y se ha comparado al clasificador *AdaBoost* con otros dos (NB y DT). En este apartado, se va a comparar *AdaBoost* con un conjunto más amplio de algoritmos. Se sustituye el clasificador DT (CART) por un clasificador más sofisticado cons-

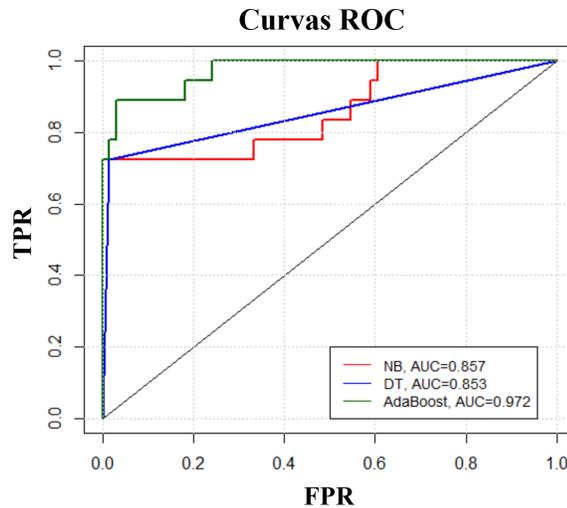


Figura 5.30: Curvas ROC de los clasificadores con agrupación OOA [161].

truido con la técnica de *Bagging*. Se mantiene el clasificador Bayesiano NB, y se añaden otros dos como K -NN y un clasificador basado en SVM con *kernel* basado en una función de base radial (*Radial Basis Function*, RBF) muy empleado como clasificador en la literatura. En esta ocasión, la comparación se reduce a los casos de $IR = 5$ y de $IR = 10$ ya que son más extremos que el caso $IR = 2$.

Para el caso de estudio anterior, se realizó un primer análisis muy genérico donde no se discriminó entre fuentes de alimentación. En los resultados que se presentan a continuación, se analiza cada caso donde el motor es alimentado por fuentes de alimentación distintas por separado. A su vez, se extiende la evaluación incluyendo análisis de significancia estadística (McNemar's Test) tal y como se desarrolló en el Capítulo 2.

Los conjuntos de datos de entrenamiento y de prueba se dividen al 50 %. Los desequilibrios de clase se provocan reduciendo las observaciones de la clase de fallo de manera aleatoria tal y como se hizo para mostrar los resultados gráficos de LSH y RSH al aplicar SMOTE. Con los datos de entrenamiento desequilibrados, se aplica SMOTE para disponer de un conjunto equilibrado y, de esta manera, calibrar el algoritmo correspondiente por medio de $0.632+Bootstrap$ obteniendo los parámetros óptimos para cada clasificador. Finalmente, se prueban las prestaciones para cada caso, del conjunto de clasificadores construidos mostrando las métricas, curvas ROC y pruebas estadísticas de los resultados obtenidos.

Para generar las clases predichas basadas en un umbral del 50% se calcula la MC, la cual permite hacer una tabulación cruzada entre la clase real a la que corresponde una observación y la clase a la que fue asignada por el clasificador. La tasa de exactitud global (*Accuracy*) se calcula junto con un intervalo de confianza del 95% para esta tasa (utilizando la prueba binomial) y una prueba unilateral para ver si la *Accuracy* es mejor que la “tasa de no información” que se toma como la clase más grande en los datos (la clase de motor sano). La tasa de no información es el valor de la *Accuracy* global que se puede lograr sin ningún modelo. Esto hace que aquellos modelos con una *Accuracy* más grande que esta tasa puedan ser considerados razonables. Sin embargo, existen otras métricas que pueden ser usadas para tener en cuenta las distribuciones de clase del conjunto de muestras. El estadístico *Kappa* (Cohen’s *Kappa*) fue diseñado para mejorar el acuerdo entre dos tasas. La métrica *Kappa* tiene en cuenta la *Accuracy* que resultaría de una simple asignación aleatoria y se define:

$$Kappa = \frac{O - E}{1 - E} \quad (5.1)$$

donde O es la *Accuracy* observada y E es el valor esperado de la *Accuracy* basado en los totales marginales de la MC. Este estadístico toma valores en el intervalo $(-1, 1)$. Un valor de 0 significa que no hay acuerdo entre las clases observadas y las predichas, mientras que un valor de 1 indica una concordancia perfecta de la predicción del modelo y las clases reales de las observaciones. Valores negativos indican que la predicción está en la dirección opuesta a la verdad, pero los valores negativos grandes rara vez ocurren. En la práctica, valores de *Kappa* entre 0.3 y 0.5 indican un acuerdo razonable. Supóngase que la *Accuracy* de un modelo es alta (90%) pero el valor esperado de la *Accuracy* es también alto (85%), el estadístico *Kappa* mostraría un valor de acuerdo moderado ($Kappa = \frac{1}{3}$) entre las clases observadas y las predichas.

Una forma común de analizar conjuntos emparejados de muestras, es decir, muestras pertenecientes a un conjunto de prueba y sus respectivos valores predichos o clases asignadas, es por medio de la prueba de McNemar. Para observaciones de pares emparejados, una forma de resumir los datos es por medio de una tabla de dos entradas conocida también como tabla de contingencia, conteniendo las mismas categorías para ambos conjuntos [161]. Además, la prueba de McNemar permite medir el acuerdo entre dos clasificaciones obtenidas para el mismo conjunto de observaciones (conjunto de prueba). En los resultados reportados a continuación, el p-valor de la prueba de McNemar permite observar si la proporción de clases es diferente entre las clases reales del conjunto de prueba y las clases predichas del

mismo conjunto. Finalmente, se incluyen los valores de las métricas *Recall* y TNR, los cuales informan de cómo es clasificada la clase de fallo y la clase de motor sano, respectivamente.

A pesar de que el análisis basado en la MC puede aportar mucha información, éste no tiene en cuenta qué ocurriría si se modificara el umbral de probabilidad de asignación a cada una de las clases de estudio. Uno de los aspectos más críticos a la hora de implementar un sistema de diagnóstico orientado al mantenimiento es la gestión o el coste de los falsos resultados (FP o FN). La herramienta de diagnóstico puede verse afectada por estas falsas indicaciones y, por lo tanto depender enormemente del punto de corte o umbral de asignación de clase que para el estudio anterior, basado en la MC, se ha considerado de 0.5. Clásicamente, la exactitud de un diagnóstico se ha evaluado en función de la sensibilidad (o *Recall*) y la especificidad. Sin embargo, una de las formas de evaluar el diagnóstico es analizar el comportamiento del clasificador atendiendo a todos los puntos de corte descritos por las curvas ROC. Siempre que el resultado de un diagnóstico pueda plantearse en términos de dicotomía (fallo o ausencia de fallo) la exactitud del diagnóstico puede definirse en función de la tasa de verdaderos positivos (TPR) y la tasa de falsos positivos (FPR). Por lo general, los resultados de los clasificadores vienen dados en términos de probabilidad de pertenencia a una de las clases haciendo necesario realizar un análisis para seleccionar el punto de corte de asignación a cada clase. En este apartado, se complementa la evaluación de los clasificadores por medio del análisis de sus curvas ROC (no paramétricas).

Caso de alimentación de red.

Primeramente, se analiza el caso de alimentación del motor directamente de la red. Los resultados numéricos correspondientes a este tipo de suministro se encuentran en las Tablas 5.15 a 5.22. La Tabla 5.15 corresponde a los resultados de $IR = 10$ donde se reportan los resultados para el caso en el que el interés está en diagnosticar correctamente la clase R2. En este caso, se puede apreciar que el clasificador construido con la técnica de *Bagging* (Bagg.) obtiene muy buenos resultados respecto al resto ya que sus valores de *Accuracy*, *Kappa*, *Recall* y TNR son bastante elevados. Para el caso donde el interés está en diagnosticar R3 frente a la clase de motor sano bajo el mismo IR de 10, los clasificadores *K-NN*, *AdaBoost* y *SVM* son los que tienen un mejor comportamiento. Para el caso de la severidad R4, los resultados obtenidos por el conjunto de clasificadores son bastante similares entre sí, a diferencia de *SVM* que tiene peores prestaciones que el resto ya que sus valores de *Kappa* y *Recall* son mucho más pequeños respecto al resto debido a que este clasificador comete

muchos FN. Finalmente, para $IR = 10$ y considerando como severidad de interés la de barra rota (R5) se observa que *Bagging* da muy buenos resultados. Es interesante apreciar que, aunque R5 es una severidad bastante desarrollada, para $IR = 10$ y con el reparto del 50 % de los datos para el conjunto de entrenamiento y de prueba los resultados obtenidos son bastante negativos respecto a aquellos obtenidos con 5 repeticiones de 10-*folds* de validación cruzada. Esto es así, porque el método de reparto de observaciones es bastante pesimista pero, sin embargo permite disponer de un conjunto de prueba suficientemente grande para realizar la comparación de las prestaciones del conjunto de clasificadores.

Las Tablas 5.19 a 5.22 corresponden a los resultados de $IR = 5$ donde se reportan los resultados para cada severidad. A diferencia del caso de $IR = 10$, se puede apreciar que el clasificador *AdaBoost* (AdaB.) mejora sus resultados junto con la técnica de *Bagging* en diagnosticar la severidad de fallo R2. Por otro lado, si observamos los resultados para la severidad R3, todas y cada una de las técnicas clasifican correctamente todas las observaciones de prueba (Tabla 5.20). Para el caso de la severidad R4, los resultados obtenidos son peores respecto a la severidad anterior. Sin embargo, esto puede ser debido a que las características de las observaciones escogidas para el conjunto de entrenamiento en este caso pueden resultar más complejas para el conjunto de clasificadores respecto a aquellas del caso anterior. No obstante, lo que resulta interesante es observar cómo afecta el desequilibrio de clase en relación a las prestaciones de los clasificadores. Finalmente, para $IR = 5$ y la severidad R5 todos los clasificadores consiguen identificar correctamente todas las observaciones del conjunto de prueba.

A continuación se presentan las curvas ROC para analizar las prestaciones de los clasificadores para cada suministro, relación de desequilibrio y severidad a diagnosticar. Además, para facilitar el análisis en cada gráfico se muestra el valor del área bajo la curva (AUC) de cada clasificador. En la Fig. 5.31 se pueden ver las curvas ROC para el caso de alimentación de red con un $IR = 10$. Para el caso de la severidad R2 se observa que el clasificador *AdaBoost* tiene un mejor rendimiento seguido del clasificador *Bagging*. Para el caso del fallo R3, los clasificadores *K-NN* y *SVM* presentan resultados óptimos, es decir, tiene una capacidad de discriminación perfecta entre las dos distribuciones sea cual sea el umbral de decisión. Sin embargo, para el caso en el que se trata de diagnosticar la severidad R4, ninguno de los clasificadores es óptimo. Los resultados para todas las técnicas son muy similares entre sí con un AUC entorno a 0.9. Finalmente, para diagnosticar la severidad R5, ante el caso $IR = 10$,

Clasificador	NB		K-NN		Bagg.		AdaB.		SVM		
	Real		Real		Real		Real		Real		
	0	1	0	1	0	1	0	1	0	1	
Predicho	0	29	9	21	7	27	0	25	6	27	12
	1	1	6	9	8	3	15	5	9	3	3
Accuracy	0.7778		0.6444		0.9333		0.7556		0.6667		
IC (95 %)	(0.63, 0.88)		(0.49, 0.78)		(0.82, 0.99)		(0.60, 0.87)		(0.51, 0.80)		
p-valor	0.074		0.687		2.43e-05		0.1331		0.5695		
Kappa	0.4231		0.2258		0.8571		0.4407		0.1176		
McNemar's Test	0.02686		0.8026		0.2482		1		0.0388		
Recall	0.4		0.53		1		0.6		0.2		
TNR	0.4		0.7		0.9		0.8333		0.9		

Tabla 5.15: Resultados de la evaluación de los clasificadores para la severidad R2. Alimentación de RED $IR = 10$.

K -NN, *Bagging* y SVM tienen un AUC igual a la unidad.

El análisis del caso de estudio con $IR = 5$ (Fig. 5.32) se puede hacer de forma breve comentando que ningún clasificador se comporta de manera óptima para diagnosticar las 4 severidades. Sin embargo, *AdaBoost* es el que mejor resultados presenta cuando se analiza con la curva ROC.

Caso de alimentación con el inversor ABB.

En segundo lugar, se analiza el caso de suministro con el inversor ABB. Los resultados numéricos correspondientes a este tipo de suministro se encuentran en las Tablas 5.23 a 5.30. La Tabla 5.23 corresponde a los resultados de $IR = 10$ donde se reportan los resultados para el caso en el que el interés está en diagnosticar correctamente la clase R2. En este caso, se puede apreciar que la *Accuracy* del clasificador NB es superior al resto. Sin embargo, atendiendo al p-valor, ningún valor de la métrica *Accuracy* del conjunto de clasificadores es estadísticamente significativo respecto al valor de la tasa de no información. Para el caso donde el interés está en diagnosticar R3 (Tabla 5.24) frente a la clase de motor sano bajo el mismo IR de 10, los clasificadores *Bagg.* y *AdaB.* tienen mejores prestaciones compartiendo los mismos valores de *Recall* y TNR. Para el caso de la severidad R4, los mejores resultados

Clasificador	NB		K-NN		Bagg.		AdaB.		SVM		
	Real		Real		Real		Real		Real		
	0	1	0	1	0	1	0	1	0	1	
Predicho	0	30	9	30	0	30	9	30	1	30	0
	1	0	6	0	15	0	6	0	14	0	15
Accuracy	0.8		1		0.8		0.9778		1		
IC (95 %)	(0.65, 0.90)		(0.92, 1)		(0.65, 0.90)		(0.88, 0.99)		(0.92, 1)		
p-valor	0.074		0.687		2.43e-05		0.1331		0.5695		
Kappa	0.4706		1		0.4706		0.9492		1		
McNemar's Test	0.0077		NA		0.0077		1		NA		
Recall	0.4		1		0.4		0.93		1		
TNR	1		1		1		0.93		1		

Tabla 5.16: Resultados de la evaluación de los clasificadores para la severidad R3. Alimentación de RED $IR = 10$.

Clasificador	NB		K-NN		Bagg.		AdaB.		SVM		
	Real		Real		Real		Real		Real		
	0	1	0	1	0	1	0	1	0	1	
Predicho	0	30	4	30	3	30	4	30	4	30	8
	1	0	11	9	12	0	11	0	11	0	7
Accuracy	0.9111		0.9333		0.9111		0.9111		0.8222		
IC (95 %)	(0.79, 0.97)		(0.82, 0.99)		(0.78, 0.97)		(0.78, 0.97)		(0.68, 0.92)		
p-valor	0.0001		2.43e-5		0.0001		0.0001		0.0164		
Kappa	0.7857		0.8421		0.7857		0.7857		0.5685		
McNemar's Test	0.1336		0.2482		0.1336		0.1336		0.0133		
Recall	0.7333		0.8		0.7333		0.7333		0.4667		
TNR	1		1		1		1		1		

Tabla 5.17: Resultados de la evaluación de los clasificadores para la severidad R4. Alimentación de RED $IR = 10$.

Clasificador	NB		K-NN		Bagg.		AdaB.		SVM		
	Real		Real		Real		Real		Real		
	0	1	0	1	0	1	0	1	0	1	
Predicho	0	29	9	21	7	27	0	25	6	27	12
	1	1	6	9	8	3	15	5	9	3	3
Accuracy	0.7778		0.6444		0.9333		0.7556		0.6667		
IC (95 %)	(0.63, 0.88)		(0.49, 0.78)		(0.82, 0.99)		(0.60, 0.87)		(0.51, 0.80)		
p-valor	0.074		0.687		2.43e-05		0.1331		0.5695		
Kappa	0.4231		0.2258		0.8571		0.4407		0.1176		
McNemar's Test	0.02686		0.8026		0.2482		1		0.0388		
Recall	0.4		0.53		1		0.6		0.2		
TNR	0.4		0.7		0.9		0.8333		0.9		

Tabla 5.18: Resultados de la evaluación de los clasificadores para la severidad R5. Alimentación de RED $IR = 10$.

Clasificador	NB		K-NN		Bagg.		AdaB.		SVM		
	Real		Real		Real		Real		Real		
	0	1	0	1	0	1	0	1	0	1	
Predicho	0	30	6	29	8	30	0	29	3	30	5
	1	0	9	1	7	0	15	1	12	0	10
Accuracy	0.8667		0.8		1		0.9111		0.8889		
IC (95 %)	(0.73, 0.95)		(0.65, 0.90)		(0.92, 1)		(0.79, 0.97)		(0.76, 0.96)		
p-valor	0.0021		0.0370		1.191e-8		0.0001		0.0006		
Kappa	0.6667		0.4906		0.8571		0.7931		0.7273		
McNemar's Test	0.0412		0.0455		NA		0.6170		0.0736		
Recall	0.6		0.47		1		0.8		0.67		
TNR	1		0.97		1		0.97		1		

Tabla 5.19: Resultados de la evaluación de los clasificadores para la severidad R2. Alimentación de RED $IR = 5$.

Clasificador	NB		K-NN		Bagg.		AdaB.		SVM	
	Real		Real		Real		Real		Real	
	0	1	0	1	0	1	0	1	0	1
Predicho	0	30	0	30	0	30	0	30	0	30
	1	0	15	0	15	0	15	0	15	0
Accuracy	1		1		1		1		1	
IC (95 %)	(0.92, 1)		(0.92, 1)		(0.92, 1)		(0.92, 1)		(0.92, 1)	
p-valor	1.191e-08									
Kappa	1		1		1		1		1	
McNemar's Test	NA									
Recall	1		1		1		0.93		1	
TNR	1		1		1		1		1	

Tabla 5.20: Resultados de la evaluación de los clasificadores para la severidad R3. Alimentación de RED $IR = 5$.

Clasificador	NB		K-NN		Bagg.		AdaB.		SVM	
	Real		Real		Real		Real		Real	
	0	1	0	1	0	1	0	1	0	1
Predicho	0	30	3	30	3	30	2	29	2	30
	1	0	12	9	12	0	13	1	13	0
Accuracy	0.9333		0.9333		0.9556		0.9333		0.9778	
IC (95 %)	(0.79, 0.97)		(0.82, 0.99)		(0.78, 0.97)		(0.78, 0.97)		(0.68, 0.92)	
p-valor	0.0001		2.43e-5		0.0001		0.0001		0.0164	
Kappa	0.8421		0.8421		0.8866		0.8475		0.9492	
McNemar's Test	0.2482		0.2482		0.4795		1		1	
Recall	0.8		0.8		0.8667		0.8667		0.9333	
TNR	1		1		1		0.9667		1	

Tabla 5.21: Resultados de la evaluación de los clasificadores para la severidad R4. Alimentación de RED $IR = 5$.

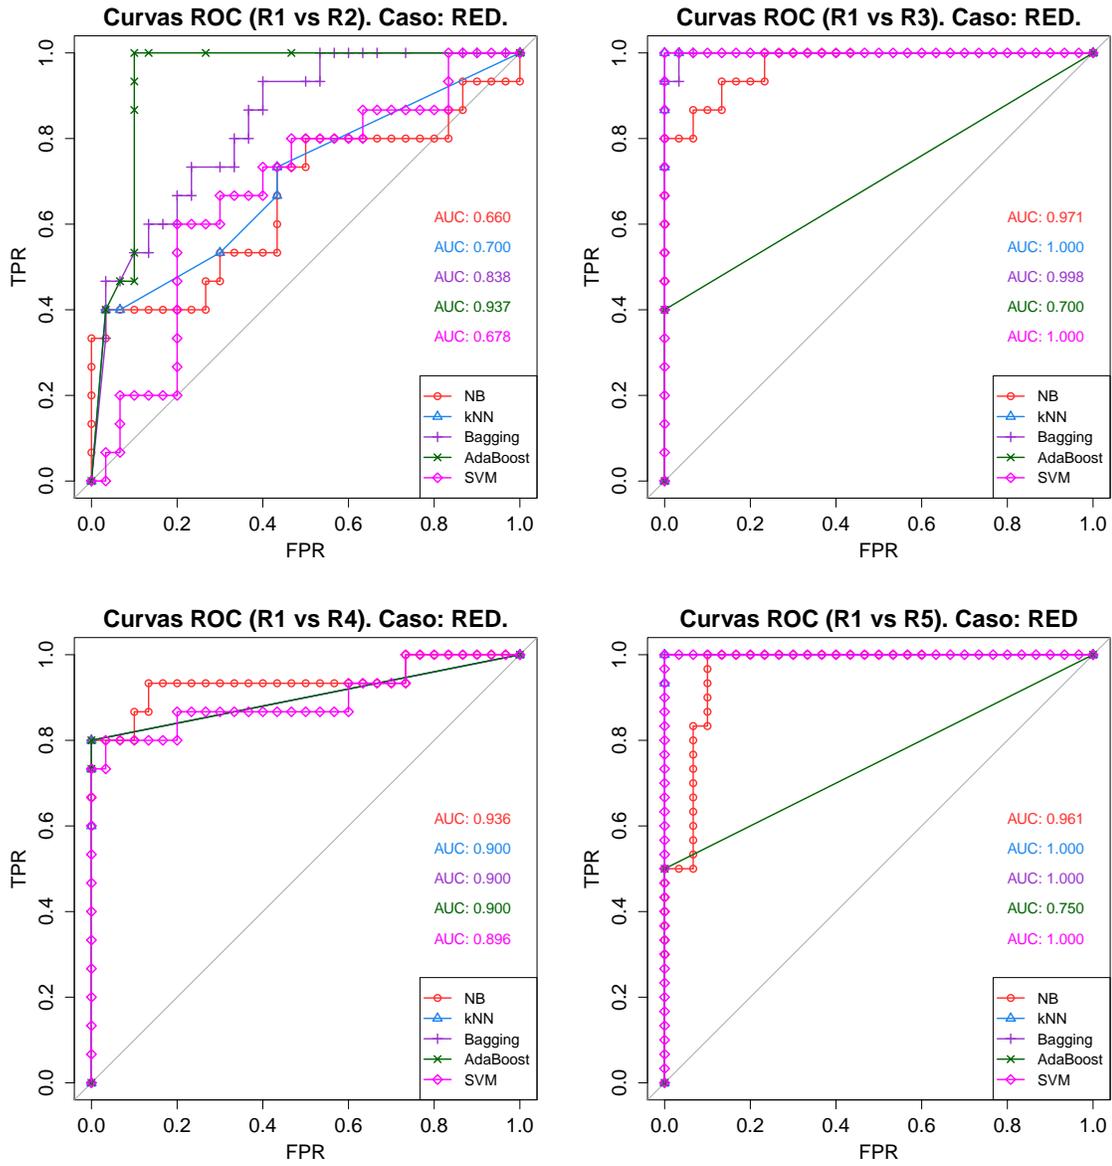


Figura 5.31: Comparación de clasificadores con datos de red tras aplicar SMOTE ($IR = 10$).

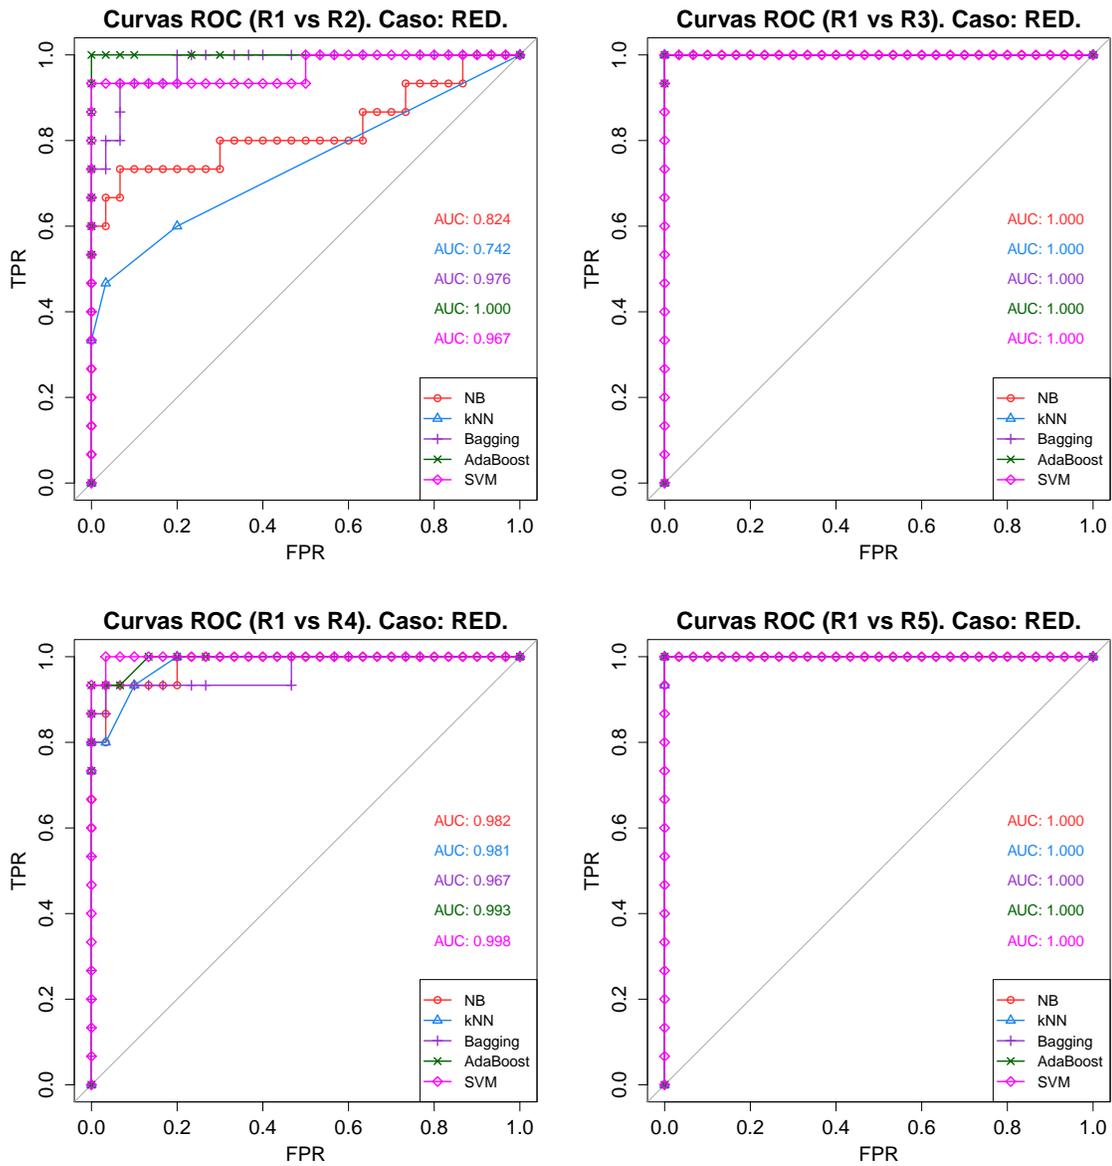


Figura 5.32: Comparación de clasificadores con datos de red tras aplicar SMOTE ($IR = 5$).

Clasificador	NB		K-NN		Bagg.		AdaB.		SVM	
	Real		Real		Real		Real		Real	
	0	1	0	1	0	1	0	1	0	1
Predicho	0	30	0	30	0	30	0	30	0	30
	1	0	15	0	15	0	15	0	15	0
Accuracy	1		1		1		1		1	
IC (95 %)	(0.92, 1)		(0.92, 1)		(0.92, 1)		(0.92, 1)		(0.92, 1)	
p-valor	1.191e-08									
Kappa	1		1		1		1		1	
McNemar's Test	NA									
Recall	1		1		1		0.93		1	
TNR	1		1		1		1		1	

Tabla 5.22: Resultados de la evaluación de los clasificadores para la severidad R5. Alimentación de RED $IR = 5$.

los obtienen los mismos clasificadores que en el caso anterior, clasificando correctamente todos los casos en los que el motor tiene un fallo de severidad R4.

Finalmente, para $IR = 10$ y considerando como severidad de interés la de barra rota (R5) se observa que *Bagging* da muy buenos resultados. Es interesante apreciar que, aunque R5 es una severidad bastante desarrollada, para $IR = 10$ y con el reparto del 50% de los datos para el conjunto de entrenamiento y de prueba los resultados obtenidos son bastante negativos respecto a aquellos obtenidos con 5 repeticiones de 10-folds de validación cruzada. Esto es así, porque el método de reparto de observaciones es bastante pesimista pero, sin embargo permite disponer de un conjunto de prueba suficientemente grande para realizar la comparación de las prestaciones del conjunto de clasificadores.

Las Tablas 5.27 a 5.30 corresponden a los resultados de $IR = 5$ donde se reportan los resultados para cada severidad cuando el motor está alimentado con el inversor ABB. Aparentemente, si se observara únicamente la métrica *Accuracy* de los clasificadores, el clasificador *AdaBoost* podría resultar ser el peor. Sin embargo, el p-valor de la prueba de hipótesis nos indica que en relación a la tasa de no información, los resultados de *Accuracy* no son significativos. Por otro lado, si observamos los resultados para la severidad R3, se observa que todos los clasificadores, a excepción de NB, tienen un rendimiento excelente sobre el conjunto

Clasificador	NB		<i>K</i> -NN		Bagg.		AdaB.		SVM		
	Real		Real		Real		Real		Real		
	0	1	0	1	0	1	0	1	0	1	
Predicho	0	28	11	27	11	25	12	24	11	29	13
	1	2	4	3	4	5	3	6	4	1	2
Accuracy	0.7111		0.6889		0.6222		0.6222		0.6889		
IC (95 %)	(0.56, 0.84)		(0.53, 0.82)		(0.46, 0.76)		(0.46, 0.76)		(0.53, 0.82)		
p-valor	0.3229		0.4441		0.7872		0.7872		0.4441		
Kappa	0.2353		0.1923		0.0377		0.0727		0.125		
McNemar's Test	0.0265		0.0614		0.1456		0.3320		0.0033		
Recall	0.2667		0.2667		0.2		0.2667		0.1333		
TNR	0.9333		0.9		0.8333		0.8		0.9667		

Tabla 5.23: Resultados de la evaluación de los clasificadores para la severidad R2. Inversor ABB $IR = 10$.

de prueba (Tabla 5.28). Para el caso de la severidad R4, los resultados obtenidos son muy similares al caso anterior, a excepción de que ahora es el clasificador *K*-NN el único que no desarrolla una clasificación perfecta de las observaciones. Finalmente, para $IR = 5$ y la severidad R5 todos los clasificadores excepto *K*-NN y SVM consiguen identificar correctamente todas las observaciones del conjunto de prueba.

Las curvas ROC para analizar las prestaciones de los clasificadores para el caso de alimentación con el inversor ABB se muestran en las Figs. 5.33- 5.34. En la Fig. 5.33 se pueden ver las curvas ROC para el caso de $IR = 10$. Como se puede observar en la Fig. 5.33 para el caso de la severidad R2, el clasificador *AdaBoost* tiene un mejor rendimiento seguido el clasificador *Bagging*. Para el caso del fallo R3, los clasificadores *Bagging*, SVM y *AdaBoost* presentan claramente mejores resultados que NB y *K*-NN para un amplio rango de puntos. Sin embargo, para el caso en el que se trata de diagnosticar la severidad R4, todos los clasificadores tienen un rendimiento óptimo con un AUC igual a la unidad. Finalmente, cuando los clasificadores se construyen con datos con un desequilibrio de $IR = 10$ para diagnosticar la severidad R5, únicamente SVM tiene un AUC igual a la unidad.

Por otro lado, cuando se estudia el caso de $IR = 5$ (Fig. 5.34) se puede ver que ningún clasificador consigue diagnosticar correctamente el estado del rotor R2. No obstante, para el

Clasificador	NB		K-NN		Bagg.		AdaB.		SVM		
	Real		Real		Real		Real		Real		
	0	1	0	1	0	1	0	1	0	1	
Predicho	0	30	11	29	9	29	2	29	2	30	15
	1	0	4	1	9	1	13	1	13	0	0
Accuracy	0.7556		0.7778		0.9333		0.9333		0.6667		
IC (95 %)	(0.60, 0.87)		(0.63, 0.89)		(0.82, 0.99)		(0.82, 0.99)		(0.51, 0.8)		
p-valor	0.1331		0.0741		2.43e-05		2.43e-05		0.0003		
Kappa	0.3265		0.4231		0.8475		0.8475		0		
McNemar's Test	0.0077		NA		0.0077		1		NA		
Recall	0.2667		0.4		0.8667		0.8667		0		
TNR	1		0.9667		0.9667		0.9667		1		

Tabla 5.24: Resultados de la evaluación de los clasificadores para la severidad R3. Inversor ABB $IR = 10$.

Clasificador	NB		K-NN		Bagg.		AdaB.		SVM		
	Real		Real		Real		Real		Real		
	0	1	0	1	0	1	0	1	0	1	
Predicho	0	30	1	29	0	30	0	30	0	30	6
	1	0	14	1	15	0	15	0	15	0	9
Accuracy	0.9778		0.9778		1		1		0.8667		
IC (95 %)	(0.88, 1)		(0.88, 1)		(0.92, 1)		(0.92, 1)		(0.73, 0.95)		
p-valor	2.8e-7		2.8e-7		1.19e-8		1.19e-8		0.0021		
Kappa	0.9492		0.9508		1		1		0.6667		
McNemar's Test	1		1		NA		NA		0.0412		
Recall	0.9333		1		1		1		0.6		
TNR	1		0.9667		1		1		1		

Tabla 5.25: Resultados de la evaluación de los clasificadores para la severidad R4. Inversor ABB $IR = 10$.

Clasificador	NB		K-NN		Bagg.		AdaB.		SVM		
	Real		Real		Real		Real		Real		
	0	1	0	1	0	1	0	1	0	1	
Predicho	0	30	11	30	9	29	13	29	11	30	14
	1	0	4	9	0	1	2	1	4	0	1
Accuracy	0.7556		0.8		0.6889		0.7333		0.6889		
IC (95 %)	(0.60, 0.87)		(0.65, 0.90)		(0.53, 0.82)		(0.58, 0.85)		(0.53, 0.82)		
p-valor	0.1331		0.0370		0.4441		0.2167		0.4441		
Kappa	0.3265		0.4706		0.125		0.28		0.087		
McNemar's Test	0.0026		0.0077		0.0033		0.0094		0.0005		
Recall	0.2667		0.4		0.1333		0.2667		0.0667		
TNR	1		1		0.9667		0.9667		1		

Tabla 5.26: Resultados de la evaluación de los clasificadores para la severidad R5. Inversor ABB $IR = 10$.

Clasificador	NB		K-NN		Bagg.		AdaB.		SVM		
	Real		Real		Real		Real		Real		
	0	1	0	1	0	1	0	1	0	1	
Predicho	0	17	8	25	13	21	12	10	5	29	14
	1	13	7	5	2	9	3	20	10	1	1
Accuracy	0.5333		0.6		0.5333		0.4444		0.6667		
IC (95 %)	(0.38, 0.68)		(0.44, 0.74)		(0.38, 0.68)		(0.3, 0.6)		(0.51, 0.80)		
p-valor	0.9780		0.8652		0.9780		0.9993		0.5695		
Kappa	0.0308		-0.0385		-0.1053		0		0.0426		
McNemar's Test	0.3827		0.0990		0.6625		0.0051		0.0019		
Recall	0.4667		0.1333		0.2		0.6667		0.0667		
TNR	0.5667		0.8333		0.7		0.33		0.9667		

Tabla 5.27: Resultados de la evaluación de los clasificadores para la severidad R2. Inversor ABB $IR = 5$.

Clasificador	NB		K-NN		Bagg.		AdaB.		SVM		
	Real		Real		Real		Real		Real		
	0	1	0	1	0	1	0	1	0	1	
Predicho	0	30	2	30	0	30	0	30	0	30	0
	1	0	13	0	15	0	15	0	15	0	15
Accuracy	0.9556		1		1		1		1		
IC (95 %)	(0.85, 0.99)		(0.92, 1)		(0.92, 1)		(0.92, 1)		(0.92, 1)		
p-valor	3.277e-6		1.191e-8		1.191e-8		1.191e-8		1.191e-8		
Kappa	0.8966		1		1		1		1		
McNemar's Test	0.4705		NA		NA		NA		NA		
Recall	0.8667		1		1		1		1		
TNR	1		1		1		1		1		

Tabla 5.28: Resultados de la evaluación de los clasificadores para la severidad R3. Inversor ABB $IR = 5$.

Clasificador	NB		K-NN		Bagg.		AdaB.		SVM		
	Real		Real		Real		Real		Real		
	0	1	0	1	0	1	0	1	0	1	
Predicho	0	30	0	29	0	30	0	30	0	30	0
	1	0	15	1	15	0	15	0	15	0	15
Accuracy	1		0.9778		1		1		1		
IC (95 %)	(0.92, 1)		(0.88, 1)		(0.92, 1)		(0.92, 1)		(0.92, 1)		
p-valor	1.191e-8		2.799e-7		1.191e-8		1.191e-8		1.191e-8		
Kappa	1		0.9508		1		1		1		
McNemar's Test	NA		1		NA		NA		NA		
Recall	1		1		1		1		1		
TNR	1		0.9667		1		1		1		

Tabla 5.29: Resultados de la evaluación de los clasificadores para la severidad R4. Inversor ABB $IR = 5$.

Clasificador	NB		K-NN		Bagg.		AdaB.		SVM	
	Real		Real		Real		Real		Real	
	0	1	0	1	0	1	0	1	0	1
Predicho	0	30	0	29	3	30	0	30	0	30
	1	0	15	1	12	0	15	0	12	0
Accuracy	1		0.9111		1		1		0.9333	
IC (95 %)	(0.92, 1)		(0.79, 0.97)		(0.92, 1)		(0.92, 1)		(0.82, 0.99)	
p-valor	1.191e-8		0.0001		1.191e-8		1.191e-8		2.435e-5	
Kappa	1		0.7931		1		1		0.8421	
McNemar's Test	NA		0.6170		NA		NA		0.2482	
Recall	1		0.8		1		1		0.8	
TNR	1		0.9667		1		1		1	

Tabla 5.30: Resultados de la evaluación de los clasificadores para la severidad R5. Inversor ABB $IR = 5$.

resto de severidades los clasificadores NB, *Bagging* y *AdaBoost* presentan un comportamiento óptimo.

Caso de alimentación con el inversor Allen Bradley.

En este apartado, se analiza el caso de suministro con el inversor Allen Bradley. Las métricas que evalúan las prestaciones para este tipo suministro se encuentran en las Tablas 5.31 a 5.38. La Tabla 5.31 muestra los resultados para $IR = 10$ donde se ha realizado una clasificación entre las clases R1 y R2. En este caso, se puede apreciar que los resultados de *AdaBoost* (*Accuracy*, *Kappa* y *Recall*) son superiores al resto de clasificadores.

Para el caso donde el interés está en diagnosticar R3 (Tabla 5.32) frente a la clase de motor sano bajo el mismo IR de 10, los clasificadores *K-NN*, *Bagg.* *AdaB.* y *SVM* tienen prestaciones muy similares entre ellos, siendo ligeramente superior para el primero de ellos. Para el caso de la severidad R4, *Bagg.* y *AdaB.* presentan un comportamiento superior seguidos de *K-NN*. Para la severidad R5 con un IR de 10 se observa que todos los clasificadores presentan las mismas prestaciones salvo el clasificador *Bagg.*

Las Tablas 5.35 a 5.38 corresponden a los resultados con un $IR = 5$ donde cada tabla corresponde a una severidad particular. Para el caso de R2, NB muestra las mejores prestaciones. Si se observan los resultados para la severidad R3, los clasificadores *K-NN* y *SVM*

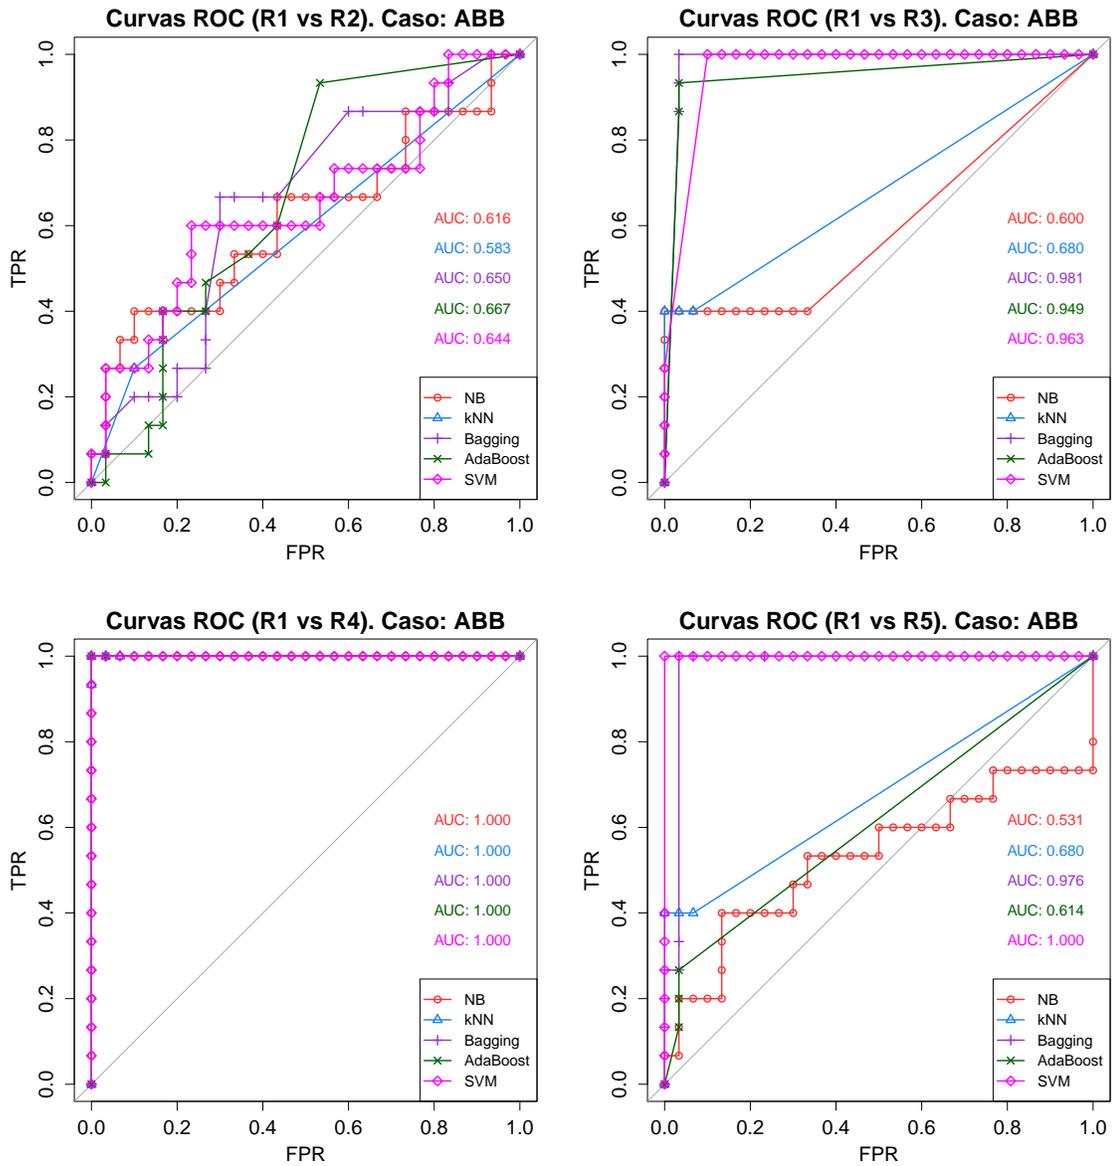


Figura 5.33: Comparación de clasificadores con datos de inversor ABB tras aplicar SMOTE ($IR = 10$).

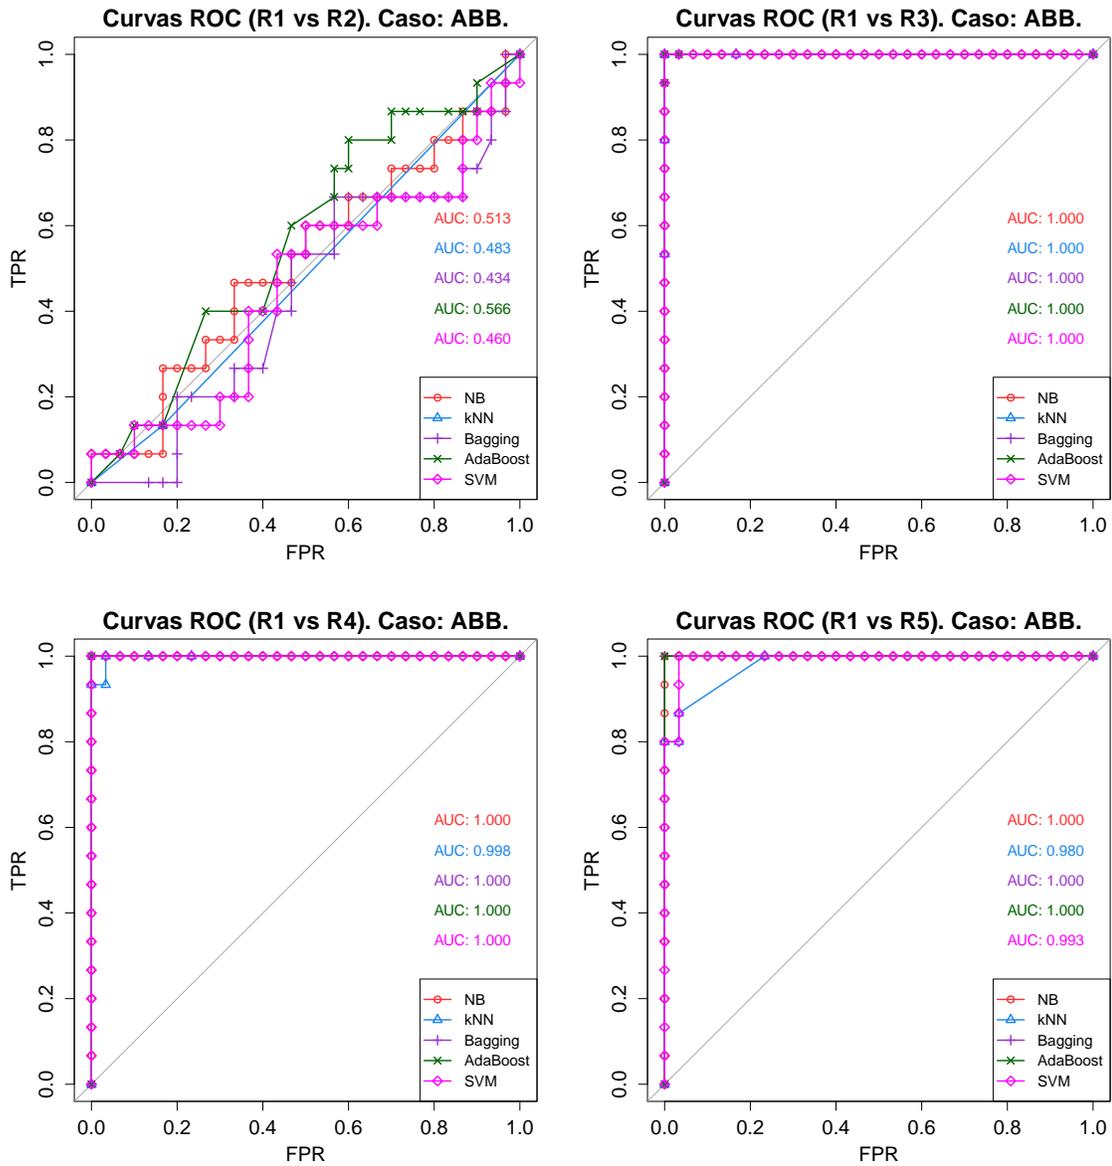


Figura 5.34: Comparación de clasificadores con datos de inversor ABB tras aplicar SMOTE ($IR = 5$).

Clasificador	NB		K-NN		Bagg.		AdaB.		SVM	
	Real		Real		Real		Real		Real	
	0	1	0	1	0	1	0	1	0	1
Predicho 0	30	13	28	5	30	7	25	5	30	9
1	0	2	2	10	0	8	1	10	0	6
Accuracy	0.7111		0.8444		0.8444		0.8667		0.8	
IC (95 %)	(0.56, 0.84)		(0.70, 0.93)		(0.70, 0.93)		(0.70, 0.93)		(0.65, 0.90)	
p-valor	0.3285		0.0063		0.0063		0.0021		0.0370	
Kappa	0.1702		0.6316		0.6038		0.6786		0.4706	
McNemar's Test	0.0009		0.4497		0.0233		0.2207		0.0077	
Recall	0.1333		0.6667		0.5333		0.6667		0.4	
TNR	1		0.9333		1		0.9667		1	

Tabla 5.31: Resultados de la evaluación de los clasificadores para la severidad R2. Inversor Allen Brad. $IR = 10$.

tienen mejores prestaciones (Tabla 5.36). Para el caso de la severidad R4, los clasificadores Bagg. y AdaB. realizan una clasificación perfecta de las observaciones de prueba. Finalmente, para $IR = 5$ y la severidad R5 todos los clasificadores consiguen identificar correctamente todas las observaciones del conjunto de prueba.

En las Figs. 5.35- 5.36 se presentan las curvas ROC para analizar las prestaciones de los clasificadores cuando el motor es alimentado a través del inversor Allen Bradley. En la Fig. 5.35 se pueden ver las curvas ROC para el caso de $IR = 10$. Como se puede observar en la Fig. 5.35 para el caso de la severidad R2, el clasificador *AdaBoost* vuelve a ser el que mejor prestaciones tiene. Sin embargo, para el caso del fallo R3, su rendimiento se reduce drásticamente mostrando mejor comportamiento SVM seguido del clasificador construido con la técnica de *Bagging*. Sin embargo, para el caso en el que se trata de diagnosticar la severidad R4, todos los clasificadores tienen un buen rendimiento destacando *Bagging*, *AdaBoost* y SVM los cuales tienen unas prestaciones óptimas. Finalmente, para diagnosticar la severidad R5, todos los clasificadores excepto NB presentan un AUC igual a la unidad.

Por otro lado, cuando se estudia el caso de $IR = 5$ (Fig. 5.36) se puede ver que en el diagnóstico del estado del rotor R2, el clasificador NB tiene mejor comportamiento que el resto seguido de *K-NN*. No obstante, para el resto de severidades los resultados obtenidos

Clasificador	NB		K-NN		Bagg.		AdaB.		SVM		
	Real		Real		Real		Real		Real		
	0	1	0	1	0	1	0	1	0	1	
Predicho	0	30	12	30	7	30	9	30	0	30	9
	1	0	3	0	8	0	6	0	6	0	6
Accuracy	0.7333		0.8444		0.8		0.8		0.8		
IC (95 %)	(0.58, 0.85)		(0.70, 0.93)		(0.65, 0.90)		(0.65, 0.90)		(0.65, 0.90)		
p-valor	0.2167		0.0063		0.0370		0.0370		0.0370		
Kappa	0.25		0.6038		0.4706		0.4706		0.4706		
McNemar's Test	0.0015		0.0234		0.0077		0.0077		0.0077		
Recall	0.2		0.5333		0.4		0.4		0.4		
TNR	1		1		1		1		1		

Tabla 5.32: Resultados de la evaluación de los clasificadores para la severidad R3. Inversor Allen Brad. $IR = 10$.

Clasificador	NB		K-NN		Bagg.		AdaB.		SVM		
	Real		Real		Real		Real		Real		
	0	1	0	1	0	1	0	1	0	1	
Predicho	0	30	11	30	1	30	0	30	0	30	15
	1	0	4	0	14	0	15	0	15	0	0
Accuracy	0.7556		0.9778		1		1		0.6667		
IC (95 %)	(0.60, 0.87)		(0.88, 1)		(0.92, 1)		(0.92, 1)		(0.51, 0.8)		
p-valor	0.1331		2.799e-7		1.191e-8		1.191e-8		0.5700		
Kappa	0.3265		0.9492		1		1		0		
McNemar's Test	0.0026		1		NA		NA		0.0003		
Recall	0.2667		0.9333		1		1		0		
TNR	1		1		1		1		1		

Tabla 5.33: Resultados de la evaluación de los clasificadores para la severidad R4. Inversor Allen Brad. $IR = 10$.

Clasificador	NB		K-NN		Bagg.		AdaB.		SVM		
	Real		Real		Real		Real		Real		
	0	1	0	1	0	1	0	1	0	1	
Predicho	0	30	9	30	9	29	10	30	9	30	9
	1	0	6	0	6	1	5	0	6	0	6
Accuracy	0.8		0.8		0.7556		0.8		0.8		
IC (95 %)	(0.65, 0.90)		(0.65, 0.90)		(0.60, 0.87)		(0.65, 0.90)		(0.65, 0.90)		
p-valor	0.0370		0.0370		0.1331		0.0370		0.0370		
Kappa	0.4706		0.4706		0.3529		0.4706		0.4706		
McNemar's Test	0.0077		0.0077		0.0159		0.0077		0.0077		
Recall	0.4		0.4		0.3333		0.4		0.4		
TNR	1		1		0.9667		1		1		

Tabla 5.34: Resultados de la evaluación de los clasificadores para la severidad R5. Inversor Allen Brad. $IR = 10$.

Clasificador	NB		K-NN		Bagg.		AdaB.		SVM		
	Real		Real		Real		Real		Real		
	0	1	0	1	0	1	0	1	0	1	
Predicho	0	30	5	26	4	28	9	23	8	30	13
	1	0	10	4	11	2	6	7	7	0	2
Accuracy	0.8889		0.8222		0.7556		0.6667		0.7111		
IC (95 %)	(0.76, 0.96)		(0.68, 0.92)		(0.60, 0.87)		(0.51, 0.80)		(0.56, 0.84)		
p-valor	0.0006		0.0164		0.1331		0.5695		0.3228		
Kappa	0.7273		0.6		0.3774		0.2373		0.1702		
McNemar's Test	0.0736		1		0.0704		1		0.0009		
Recall	0.667		0.7333		0.4		0.4667		0.1333		
TNR	1		0.8667		0.9333		0.7667		1		

Tabla 5.35: Resultados de la evaluación de los clasificadores para la severidad R2. Inversor Allen Brad. $IR = 5$.

Clasificador	NB		K-NN		Bagg.		AdaB.		SVM		
	Real		Real		Real		Real		Real		
	0	1	0	1	0	1	0	1	0	1	
Predicho	0	30	5	30	0	27	0	27	0	30	2
	1	0	10	0	15	3	15	3	15	0	13
Accuracy	0.8889		1		0.9333		0.9333		0.9556		
IC (95 %)	(0.76, 0.96)		(0.92, 1)		(0.82, 0.99)		(0.82, 0.99)		(0.85, 0.99)		
p-valor	0.0006		1.191e-8		2.435e-05		2.435e-5		3.227e-6		
Kappa	0.7273		1		0.8571		0.8571		0.8966		
McNemar's Test	0.0736		NA		0.2482		0.2482		0.4795		
Recall	0.6667		1		1		1		0.8667		
TNR	1		1		0.9		0.9		1		

Tabla 5.36: Resultados de la evaluación de los clasificadores para la severidad R3. Inversor Allen Brad. $IR = 5$.

Clasificador	NB		K-NN		Bagg.		AdaB.		SVM		
	Real		Real		Real		Real		Real		
	0	1	0	1	0	1	0	1	0	1	
Predicho	0	30	1	28	1	30	0	30	0	30	4
	1	0	14	2	14	0	15	0	15	0	11
Accuracy	0.9778		0.9333		1		1		0.9111		
IC (95 %)	(0.88, 1)		(0.82, 0.99)		(0.92, 1)		(0.92, 1)		(0.79, 0.97)		
p-valor	2.799e-7		2.43e-5		1.191e-8		1.191e-8		0.0001		
Kappa	0.9492		0.8525		1		1		0.7857		
McNemar's Test	1		1		NA		NA		0.0001		
Recall	0.9333		0.9333		1		1		0.7333		
TNR	1		0.9333		1		1		1		

Tabla 5.37: Resultados de la evaluación de los clasificadores para la severidad R4. Inversor Allen Brad. $IR = 5$.

Clasificador	NB		K-NN		Bagg.		AdaB.		SVM	
	Real		Real		Real		Real		Real	
	0	1	0	1	0	1	0	1	0	1
Predicho	0	30	0	30	0	30	0	30	0	30
	1	0	15	0	15	0	15	0	15	0
Accuracy	1		1		1		1		1	
IC (95 %)	(0.92, 1)		(0.92, 1)		(0.92, 1)		(0.92, 1)		(0.92, 1)	
p-valor	1.191e-8									
Kappa	1		1		1		1		1	
McNemar's Test	NA									
Recall	1		1		1		1		1	
TNR	1		1		1		1		1	

Tabla 5.38: Resultados de la evaluación de los clasificadores para la severidad R5. Inversor Allen Brad. $IR = 5$.

con las curvas ROC son mucho mejores. En particular, SVM destaca ligeramente por encima del resto.

Caso de alimentación con el inversor Telemecanique.

En este apartado, se analiza el caso de suministro con el inversor Telemecanique. Las métricas que evalúan las prestaciones para este tipo de suministro se encuentran en las Tablas 5.39 a 5.46. La Tabla 5.39 muestra los resultados para $IR = 10$ donde la severidad a detectar ha sido la R2. En este caso, se puede apreciar que los resultados de todos los clasificadores no son estadísticamente significativos respecto de la tasa de no información.

Para el caso de la severidad R3 (Tabla 5.40) frente a la clase de motor sano bajo el mismo IR de 10, los clasificadores K-NN, Bagg. y AdaB. tienen prestaciones muy similares entre ellos. En la Tabla 5.41 se estudia el caso de la severidad R4. En este caso, K-NN presentan un comportamiento superior al resto, seguido por AdaB. y SVM. Para la severidad R5 con un IR de 10 se observa que los clasificadores Bagg. y AdaB. presentan las mismas prestaciones, clasificando correctamente todas las observaciones.

Las Tablas 5.43 a 5.46 corresponden a los resultados tras equilibrar un conjunto con un $IR = 5$ con SMOTE. Cada tabla corresponde a una severidad particular. Para el caso de R2, al igual que en el caso anterior, NB muestra las mejores prestaciones. Si se observan los

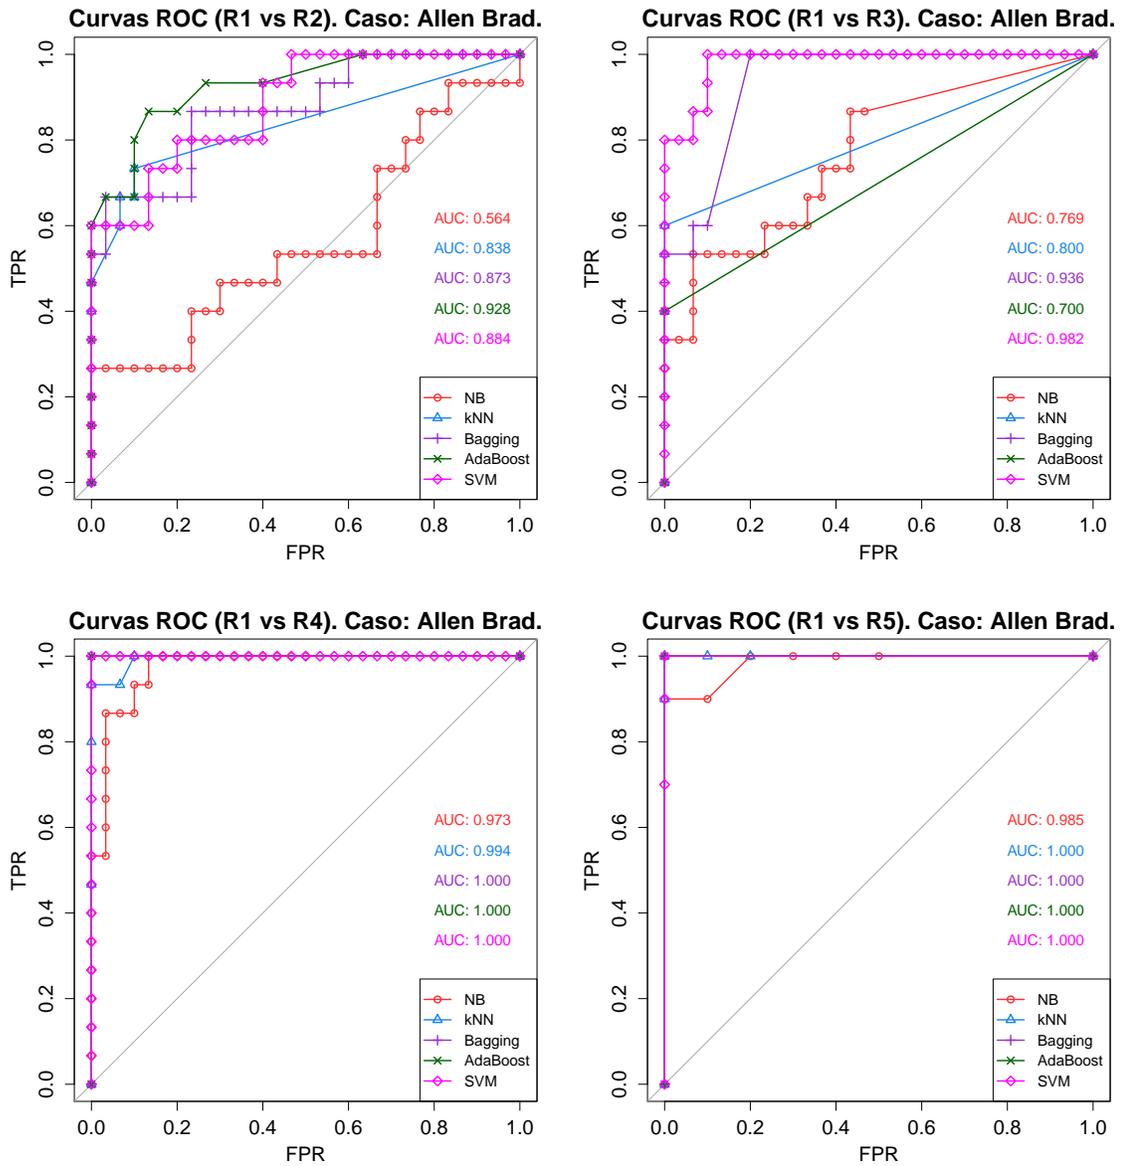


Figura 5.35: Comparación de clasificadores con datos de inversor Allen Brad. tras aplicar SMOTE ($IR = 10$).

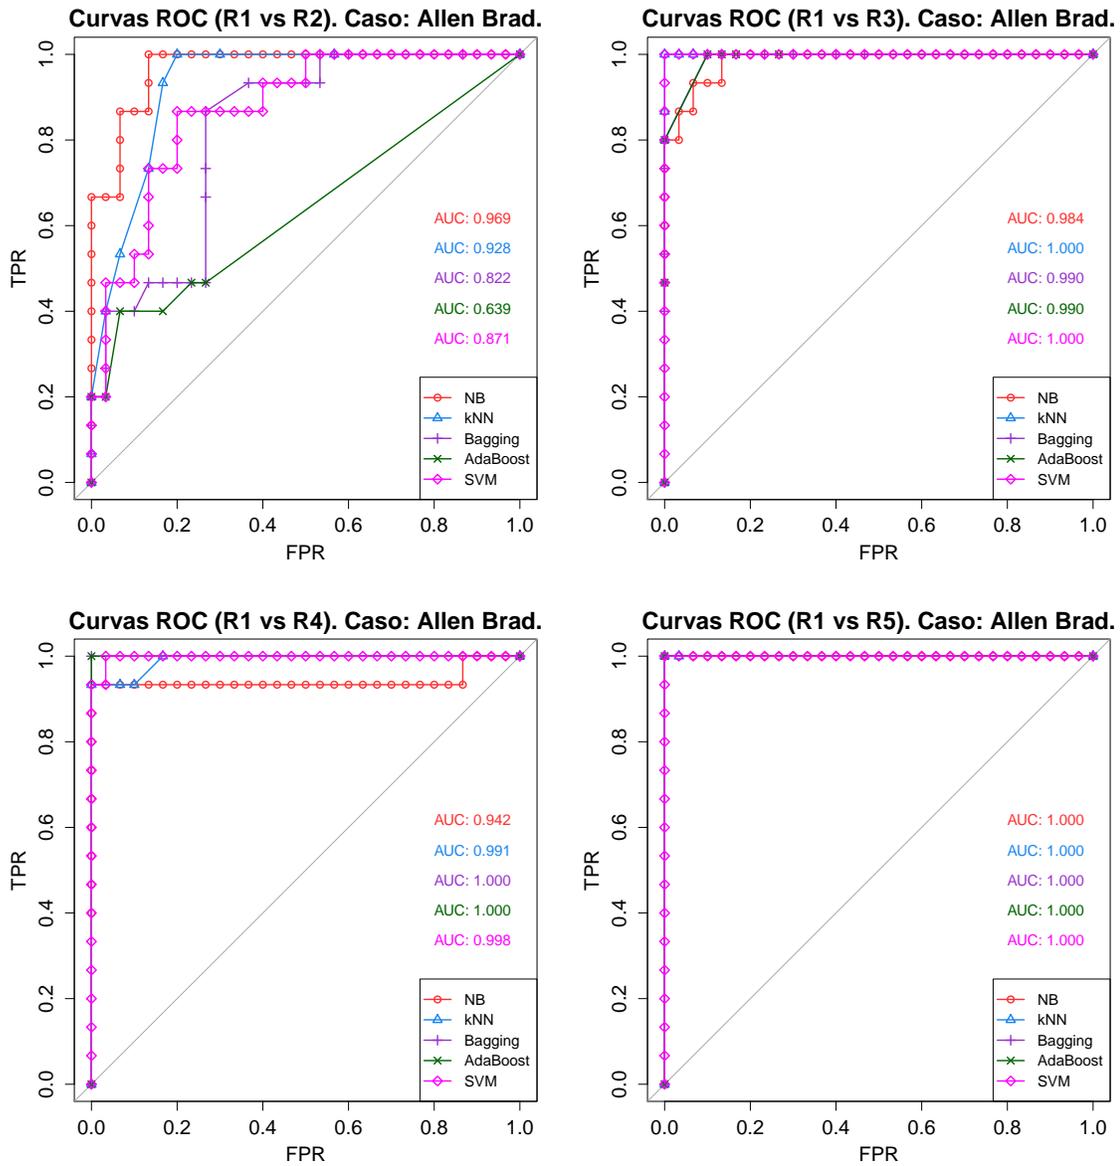


Figura 5.36: Comparación de clasificadores con datos de inversor Allen Brad. tras aplicar SMOTE ($IR = 5$)

Clasificador	NB		K-NN		Bagg.		AdaB.		SVM		
	Real		Real		Real		Real		Real		
	0	1	0	1	0	1	0	1	0	1	
Predicho	0	10	15	8	6	10	8	10	8	10	15
	1	0	0	2	9	0	7	0	7	0	0
Accuracy	0.4		0.68		0.68		0.68		0.4		
IC (95 %)	(0.21, 0.61)		(0.46, 0.85)		(0.46, 0.85)		(0.46, 0.85)		(0.21, 0.61)		
p-valor	0.9868		0.2735		0.2735		0.2753		0.9868		
Kappa	0		0.375		0.4118		0.4118		0		
McNemar's Test	0.0003		0.2888		0.0133		0.0133		0.0003		
Recall	0		0.6		0.4667		0.4667		0		
TNR	1		0.8		1		1		1		

Tabla 5.39: Resultados de la evaluación de los clasificadores para la severidad R2. Inversor Telemecanique $IR = 10$.

resultados para la severidad R3, los clasificadores Bagg. y AdaB. tienen mejores prestaciones (ver Tabla 5.44). Finalmente, tanto para el caso de la severidad R4 como para la severidad R5, los clasificadores Bagg. y AdaB. realizan una clasificación perfecta de las observaciones de prueba en ambos casos mostrando unas prestaciones mucho mejores que el resto.

En las Figs. 5.37- 5.38 se presentan las curvas ROC para analizar las prestaciones de los clasificadores cuando el motor es alimentado con el inversor de Telemecanique. En la Fig. 5.37 se pueden ver las curvas ROC para el caso de $IR = 10$. Como se puede observar en la Fig. 5.37 para el caso de la severidad R2, los clasificadores *AdaBoost* y *Bagging* son los que mejores prestaciones tienen para la mayoría de puntos de corte en el espacio ROC. Sin embargo, para el caso de fallo R3 y R4, SVM presenta un comportamiento óptimo sea cual sea el umbral escogido. Finalmente, para diagnosticar la severidad R5, únicamente los clasificadores *AdaBoost*, *Bagging* y *k-NN* presentan un comportamiento óptimo.

Por otro lado, cuando se estudia el caso de $IR = 5$ (Fig. 5.38) se puede ver que para diagnosticar el estado de rotor R2, el clasificador NB tiene comportamiento más liberal que el resto ya que para valores de $FPR < 0.2$ presenta mejor TPR. Para la severidad R4, NB, *AdaBoost* y *Bagging* destacan por encima del resto. Finalmente, para el diagnóstico de una barra completamente rota (R5) *AdaBoost* y *Bagging* presentan un comportamiento óptimo.

Clasificador	NB		K-NN		Bagg.		AdaB.		SVM		
	Real		Real		Real		Real		Real		
	0	1	0	1	0	1	0	1	0	1	
Predicho	0	10	10	10	4	10	4	10	4	10	15
	1	0	5	0	11	0	11	0	11	0	0
Accuracy	0.6		0.84		0.84		0.84		0.4		
IC (95 %)	(0.39, 0.79)		(0.64, 0.95)		(0.64, 0.95)		(0.64, 0.95)		(0.21, 0.61)		
p-valor	0.5857		0.0095		0.0095		0.0095		0.9868		
Kappa	0.2857		0.6875		0.6875		0.6875		0		
McNemar's Test	0.0044		0.1336		0.1336		0.1336		0.0003		
Recall	0.3333		0.7333		0.7333		0.7333		0		
TNR	1		1		1		1		1		

Tabla 5.40: Resultados de la evaluación de los clasificadores para la severidad R3. Inversor Telemecanique $IR = 10$.

Clasificador	NB		K-NN		Bagg.		AdaB.		SVM		
	Real		Real		Real		Real		Real		
	0	1	0	1	0	1	0	1	0	1	
Predicho	0	10	14	10	1	10	4	10	2	10	2
	1	0	1	0	14	0	11	0	13	0	13
Accuracy	0.44		0.96		0.84		0.92		0.92		
IC (95 %)	(0.24, 0.65)		(0.80, 0.99)		(0.64, 0.95)		(0.74, 0.99)		(0.74, 0.99)		
p-valor	0.9556		5.023e-5		0.0095		0.0004		0.0004		
Kappa	0.0541		0.918		0.6875		0.8387		0.8387		
McNemar's Test	0.0005		1		0.1336		0.4795		0.4795		
Recall	0.0667		0.9333		0.7333		0.8667		0.8667		
TNR	1		1		1		1		1		

Tabla 5.41: Resultados de la evaluación de los clasificadores para la severidad R4. Inversor Telemecanique $IR = 10$.

Clasificador	NB		K-NN		Bagg.		AdaB.		SVM		
	Real		Real		Real		Real		Real		
	0	1	0	1	0	1	0	1	0	1	
Predicho	0	10	14	10	2	10	0	10	0	10	15
	1	0	1	0	13	0	15	0	15	0	0
Accuracy	0.44		0.92		1		1		0.4		
IC (95 %)	(0.24, 0.65)		(0.74, 0.99)		(0.86, 1)		(0.86, 1)		(0.21, 0.61)		
p-valor	0.9656		0.0004		2.84e-6		2.84e-6		0.9868		
Kappa	0.0541		0.8387		1		1		0		
McNemar's Test	0.0005		0.4795		NA		NA		0.0003		
Recall	0.0067		0.8667		1		1		0		
TNR	1		1		1		1		1		

Tabla 5.42: Resultados de la evaluación de los clasificadores para la severidad R5. Inversor Telemecanique $IR = 10$.

Clasificador	NB		K-NN		Bagg.		AdaB.		SVM		
	Real		Real		Real		Real		Real		
	0	1	0	1	0	1	0	1	0	1	
Predicho	0	15	8	15	9	15	12	15	12	15	12
	1	0	7	5	6	0	3	0	3	0	3
Accuracy	0.7333		0.5333		0.6		0.6		0.5333		
IC (95 %)	(0.54, 0.88)		(0.34, 0.72)		(0.42, 0.77)		(0.41, 0.77)		(0.34, 0.72)		
p-valor	0.0081		0.4278		0.1808		0.0015		0.4278		
Kappa	0.4667		0.0667		0.2		0.2		0.0667		
McNemar's Test	0.0133		0.4227		0.0015		0.0015		0.0005		
Recall	0.4667		0.4		0.2		0.2		0.0667		
TNR	1		0.6667		1		1		1		

Tabla 5.43: Resultados de la evaluación de los clasificadores para la severidad R2. Inversor Telemecanique $IR = 5$.

Clasificador	NB		K-NN		Bagg.		AdaB.		SVM		
	Real		Real		Real		Real		Real		
	0	1	0	1	0	1	0	1	0	1	
Predicho	0	15	8	14	7	15	4	15	4	15	5
	1	0	7	1	8	0	11	0	11	0	10
Accuracy	0.7333		0.7333		0.8667		0.8667		0.8333		
IC (95 %)	(0.54, 0.88)		(0.54, 0.88)		(0.69, 0.96)		(0.69, 0.96)		(0.65, 94)		
p-valor	0.0081		0.0081		2.97e-05		2.97e-05		0.0002		
Kappa	0.4667		0.4667		0.7333		0.7333		0.6667		
McNemar's Test	0.0133		0.0771		0.1336		0.1336		0.0736		
Recall	0.4667		0.5333		0.7333		0.7333		0.6667		
TNR	1		0.9333		1		1		1		

Tabla 5.44: Resultados de la evaluación de los clasificadores para la severidad R3. Alimentación de RED $IR = 5$.

Clasificador	NB		K-NN		Bagg.		AdaB.		SVM		
	Real		Real		Real		Real		Real		
	0	1	0	1	0	1	0	1	0	1	
Predicho	0	15	0	13	1	15	0	15	0	15	1
	1	0	15	2	14	0	15	0	15	0	14
Accuracy	1		0.9		1		1		0.9667		
IC (95 %)	(0.88, 1)		(0.73, 0.98)		(0.88, 1)		(0.88, 1)		(0.83, 1)		
p-valor	9.31e-10		4.21e-6		9.31e-10		9.31e-10		2.89e-8		
Kappa	1		0.8		1		1		0.9333		
McNemar's Test	NA		1		NA		NA		1		
Recall	1		0.9333		1		1		0.9333		
TNR	1		0.8667		1		1		1		

Tabla 5.45: Resultados de la evaluación de los clasificadores para la severidad R4. Inversor Telemecanique $IR = 5$.

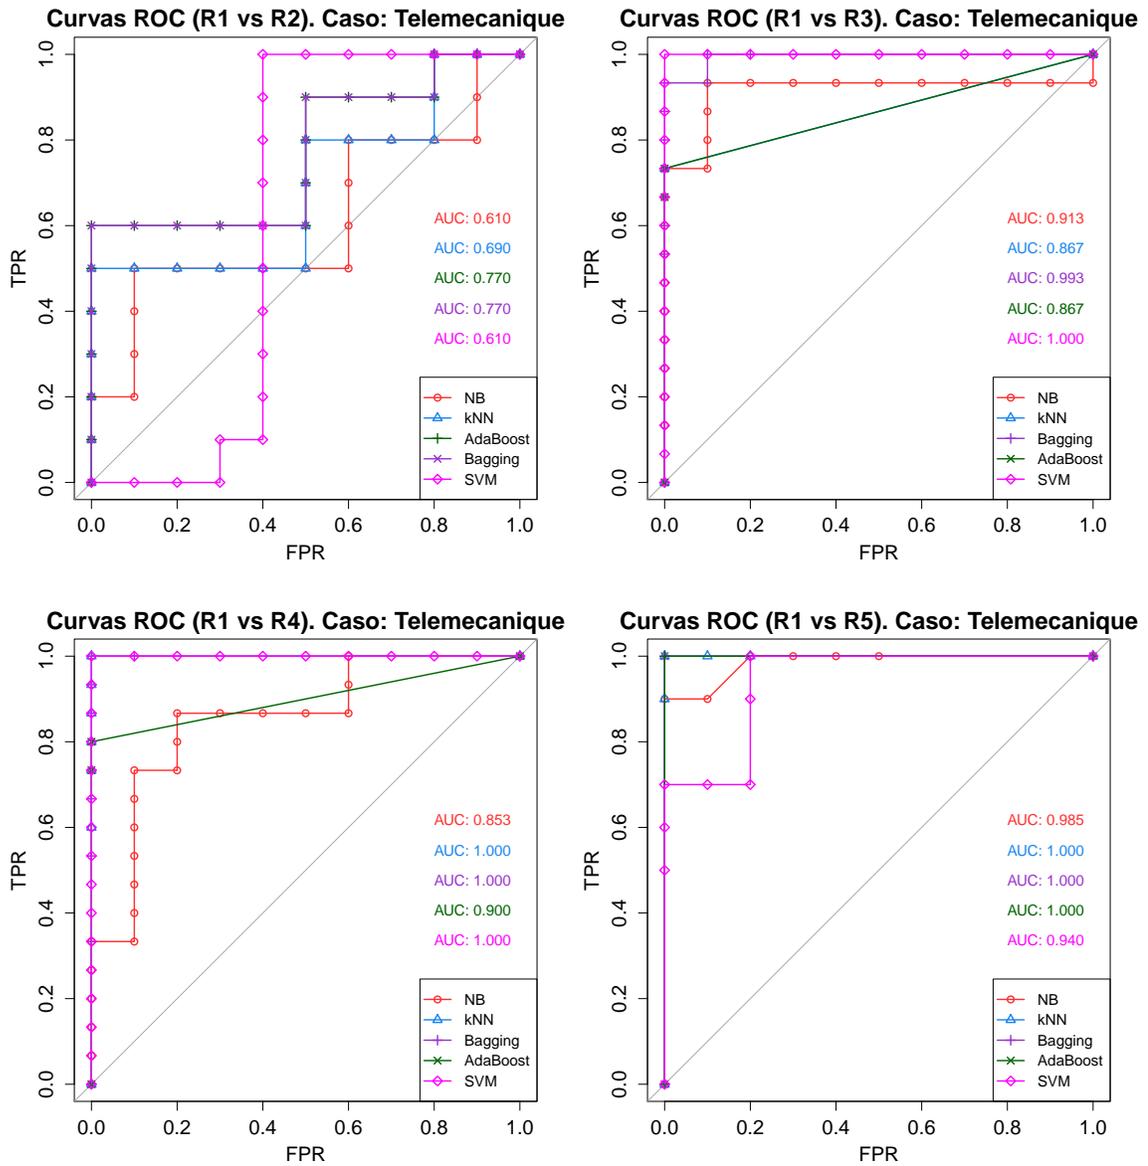


Figura 5.37: Comparación de clasificadores con datos de inversor TM tras aplicar SMOTE ($IR = 10$).

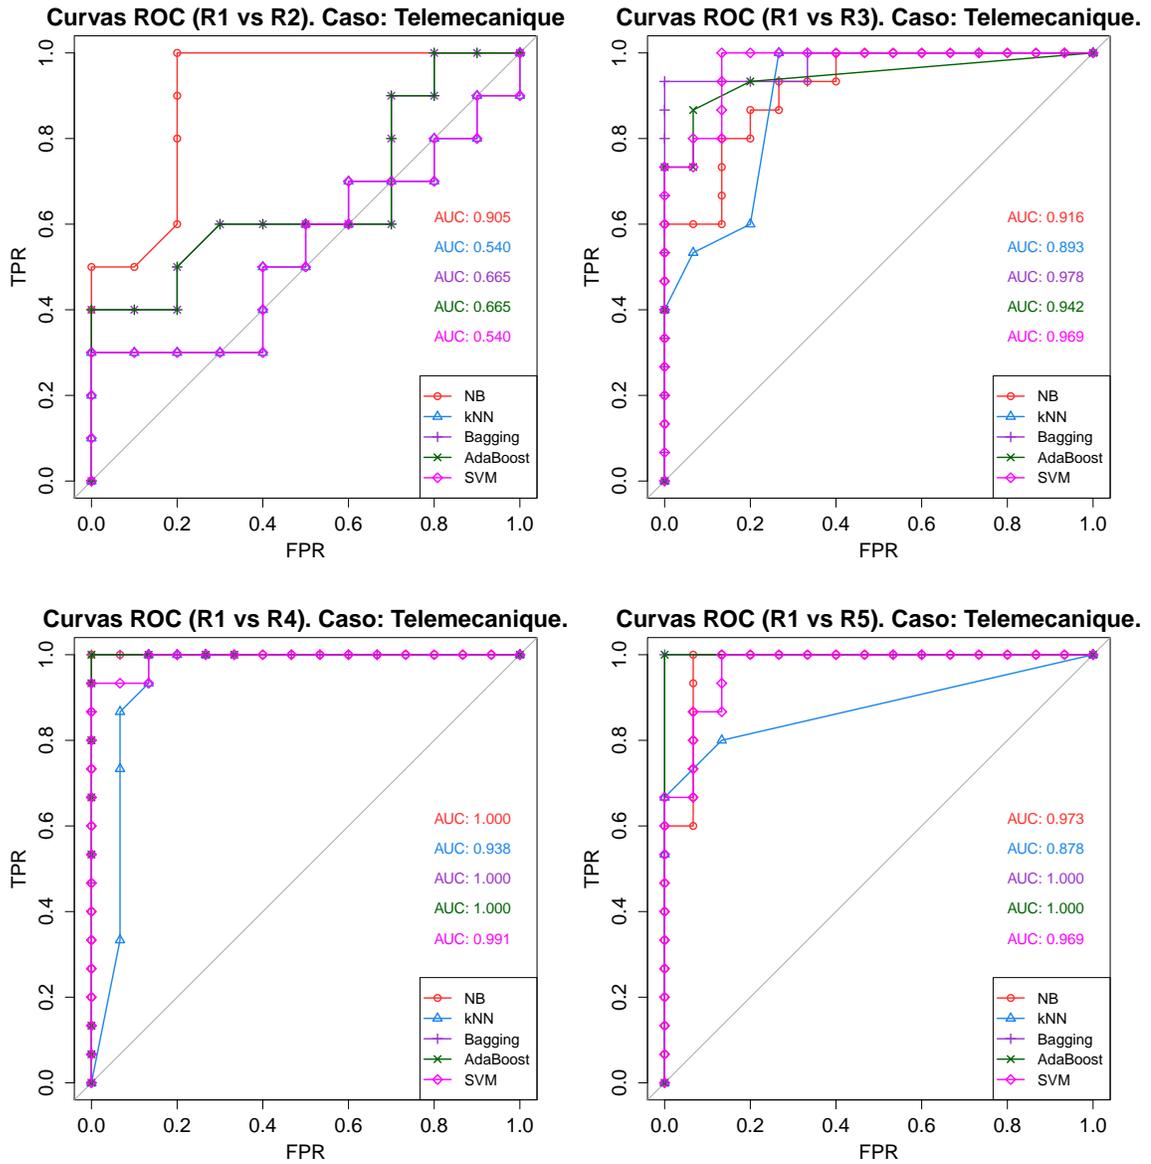


Figura 5.38: Comparación de clasificadores con datos de inversor TM tras aplicar SMOTE ($IR = 5$).

Clasificador	NB		K-NN		Bagg.		AdaB.		SVM		
	Real		Real		Real		Real		Real		
	0	1	0	1	0	1	0	1	0	1	
Predicho	0	15	7	15	5	15	0	15	0	15	15
	1	0	8	0	10	0	15	0	15	0	0
Accuracy	0.7667		0.8333		1		1		0.5		
IC (95 %)	(0.58, 0.90)		(0.65, 0.94)		(0.88, 1)		(0.88, 1)		(0.31, 0.69)		
p-valor	0.0026		0.0002		9.31e-10		9.31e-10		0.5722		
Kappa	0.5333		0.6667		1		1		0		
McNemar's Test	0.0233		0.0736		NA		NA		0.0003		
Recall	0.5333		0.6667		1		1		0		
TNR	1		1		1		1		1		

Tabla 5.46: Resultados de la evaluación de los clasificadores para la severidad R5. Inversor Telemecanique $IR = 5$.

5.10. Conclusiones del capítulo.

La detección de las frecuencias de fallo basada en el algoritmo MUSIC proporciona resultados favorables para señales ruidosas obtenidas de diferentes fuentes de alimentación permitiendo identificar severidades de media barra rota (R3). Se ha observado que la elección de los parámetros de ajuste de MUSIC dependen del nivel de carga y de la fuente de alimentación considerada. La propuesta metodológica basada en MUSIC requiere una búsqueda de sus parámetros a través de una configuración fuera de línea para identificar correctamente los órdenes de mayor discriminación. Esto es debido a que durante el análisis de las señales obtenidas en el laboratorio se ha observado que un único orden de MUSIC no permite identificar el fallo incipiente de media barra rota bajo condiciones de alimentación por inversor. Esto ha dado lugar a la selección de tres órdenes que permite identificar (en algunos casos) fallos de media barra rota en MI. El contenido de ruido, procedente de diferentes inversores, ha sido analizado en el contexto de su influencia en la detección del fallo observándose diferencias para cada nivel de carga considerado. Para detección en el estado estacionario, se puede concluir que MUSIC proporciona mejores resultados que los obtenidos con la FFT, ya que ésta no permite localizar los componentes de frecuencia de un fallo de media barra rota. Sin embargo, la FFT ayuda a cuantificar el fallo una vez que se ha localizado la frecuencia característica del mismo con MUSIC.

Por otro lado, en este capítulo se ha comprobado que los métodos de selección de características basados en técnicas de filtrado así como la técnica propuesta de eliminación recursiva de características a través del algoritmo *Random Forest* (RF-RFE) han coincidido a la hora de seleccionar las variables más relevantes para la etapa de clasificación. Sin embargo, ha sido la técnica RF-RFE la que ha permitido seleccionar el número óptimo de características a través de la optimización de la métrica *Accuracy* con el algoritmo RF. Además, se ha observado que dependiendo del tipo de suministro de energía las variables elegidas por cada método difieren notablemente. En particular, para el inversor más ruidoso (Telemecanique) se ha comprobado que algunas de las características basadas en el dominio del tiempo de la señal son más relevantes para la clasificación que el propio LSH y RSH.

En este capítulo se ha comprobado que los conjuntos de datos desequilibrados agudizan la problemática del diagnóstico automático de fallos en el rotor de un MI. Además, si el diagnóstico automático se pretende implantar en MI alimentados por inversor los resultados pueden depender de forma significativa del tipo de fuente empleada. Una conclusión clara de la metodología propuesta es que la técnica de SMOTE mejora el rendimiento del clasificador una vez que las observaciones de los casos de fallo aumentan su representación. El clasificador de *AdaBoost* junto con la técnica de *Bagging* parecen enfoques prometedores para su empleo en la etapa de clasificación ya que no requieren del calibrado de parámetros complejos de ajuste como en el caso de SVM o *K*-NN.

El uso combinado de SMOTE y *Adaboost* ha demostrado que, en presencia de tamaños variables del conjunto de datos (para el mismo IR) y bajo diferente número de relaciones desequilibradas, presenta resultados bastante estables. En este capítulo se presentó una comparación del desempeño de los clasificadores estudiados en esta tesis, *Naive-Bayes*, Árboles de Decisión (CART), *K*-NN, máquinas de soporte vectorial (SVM), *Bagging* y *AdaBoost*. A la vista de los resultados se puede decir que, en términos generales los algoritmos *Bagging*, *AdaBoost* y SVM son los que obtuvieron rendimientos más elevados. La ventaja que tiene *AdaBoost*, es que sin modificar su parámetro de ajuste (número de árboles) para un clasificador débil basado en árboles de decisión para todos los casos de estudio considerados sus resultados han sido muy favorables. Por contra, SVM ha requerido ser ajustado con los datos de entrenamiento para cada caso lo cual es un inconveniente para su empleo como herramienta de diagnóstico.

Como se ha comprobado durante en este capítulo, la elección de un correcto funcionamiento del clasificador depende enormemente de su fase de evaluación. Está claro que existen métricas como la Accuracy que no permiten evaluar las prestaciones de la clasificación cuando el conjunto de datos de prueba es desequilibrado. Además, se ha comprobado que para su evaluación es necesario realizar una prueba estadística para apreciar si esos resultados se deben a la labor del clasificador o si en cambio, pueden ser atribuidos a una ocurrencia azarosa. Por otro lado, métricas como Recall y Precision aportan información sobre el comportamiento del clasificador cuando el interés en diagnosticar la clase de motor con fallo predomina sobre la clase de motor sano. Por contra, cuando interese más la clase de motor sano, la TNR es una buena métrica.

Capítulo 6

Conclusiones y aportaciones.

En este capítulo final de la tesis se exponen las conclusiones y aportaciones que se derivan de los resultados obtenidos de la aplicación de las metodologías de diagnóstico propuestas. Posteriormente se indican las publicaciones a las que ha dado lugar la presente tesis. Finalmente, el capítulo termina con las perspectivas abiertas tras realizar este proceso de formación doctoral.

6.1. Conclusiones técnicas del trabajo.

Los objetivos e hipótesis iniciales han determinado los pasos de cada una de las etapas de las metodologías desarrolladas. La investigación y propuesta de soluciones para la generación de observaciones sintéticas para equilibrar el conjunto de datos de entrenamiento y poder inducir clasificadores más eficaces para el diagnóstico de fallos mecánicos en el rotor ha sido el principal enfoque de esta tesis. Para lograr este objetivo, el primer paso ha sido la identificación de los principales factores que determinan las prestaciones de un sistema de diagnóstico automático de fallos mecánicos en el rotor basado en el análisis de la corriente de alimentación del motor. Por lo tanto, como ha sido explicado en el documento, las etapas de adquisición de datos, cálculo de características, selección de características, e inducción del clasificador han representado los principales aspectos en los que se ha enfocado esta tesis. Cabe señalar que las investigaciones y contribuciones relacionadas con el esquema propuesto de diagnóstico se han realizado bajo requisitos significativos exigidos para la herramienta de diagnóstico objeto de estudio, la cual ha consistido en el siguiente conjunto de pasos.

Desarrollo de una metodología para la localización y cuantificación de fallos incipientes en estado estable.

A través de la revisión de los antecedentes se ha investigado profundamente la problemática de localizar las frecuencias características de fallo con la FFT cuando un MI es alimentado por medio de un inversor.

Se ha desarrollado una metodología para, utilizando la corriente de alimentación de un MI, identificar y cuantificar fallos incipientes en el rotor. Primeramente, se trata de localizar la frecuencia de fallo a través de la transformada MUSIC escogiendo el orden adecuado para el tipo de alimentación en cuestión. Posteriormente, con la FFT se cuantifica la severidad del fallo a través de las amplitudes de los armónicos característicos del fallo de rotura de barras. Para ello se observó que es necesario al menos, un tiempo de adquisición de 10 s para tener una buena resolución en frecuencia.

Se ha observado que una elección incorrecta del orden de MUSIC puede llegar a arrojar falsos resultados. De ahí, surgió la necesidad de proponer una técnica de selección del orden de MUSIC basada en la elección de los estadísticos de orden. Para ello se emplearon conjuntos de señales obtenidos en el laboratorio. Además, se ha verificado que para ciertos tipos de alimentación, como lo es el caso de TM, donde el nivel de cesped es muy elevado, ni siquiera MUSIC puede identificar las frecuencias de fallo de barra rota cuando el MI desarrolla un fallo de media barra rota. También se ha observado lo siguiente:

- Para la detección de fallos con una barra completamente rota, la elección de un único orden de MUSIC resulta suficiente. Sin embargo, no ocurre así para la detección del fallo incipiente donde se necesita obtener más información de la señal. Por ello, se escogieron tres órdenes de MUSIC que ayudan a discriminar mejor entre el estado de motor sano y motor con fallo R3.
- Para todos los tipos de alimentación considerados en esta tesis se logra detectar el fallo R5 con un único orden de MUSIC.
- La mayor dificultad en detectar la severidad de fallo R3 surge para las señales correspondientes a un MI de las características descritas funcionando con una carga NC1.

La principal ventaja de MUSIC para identificar las componentes de fallo es que no requiere utilizar sensores adicionales para el cálculo de la velocidad. Sin embargo, hay que tener

en cuenta las limitaciones del método presentado, tales como la influencia de la fuente de alimentación y el nivel de carga, para obtener las frecuencias de fallo, y por tanto, para su aplicación en la metodología de diagnóstico automático.

Aplicación de métodos para la selección de características con diferentes fuentes de alimentación.

Dentro de la revisión realizada se aprecia que existen varias técnicas de reducción y selección de características que resultan más o menos apropiadas según las características del conjunto de datos. Por otro lado, a pesar de las ventajas de las técnicas de reducción de características, éstas tienen el inconveniente de que se pierde el sentido físico de las variables finales a las que se redujo el conjunto original. Por ello, el objetivo de las técnicas de selección de características aplicadas en esta tesis, aparte de analizar qué variables están correlacionadas y cómo es su relación con el resto (lineal o no lineal), es analizar el grado de relevancia de cada una de ellas en relación al proceso de clasificación. En esta tesis se han desarrollado contribuciones correspondientes tanto a enfoques de ordenamiento de características (métodos de filtrado) como a través de un enfoque novedoso donde se determinan qué variables son las óptimas para la etapa de clasificación. Se ha propuesto la aplicación combinada del algoritmo *Random Forest* con la técnica de eliminación recursiva de características para determinar el número y la identidad de las variables más relevantes para cada caso estudiado. Los resultados de la etapa de selección de características han mostrado que las tres técnicas de filtrado empleadas (Ganancia de Información, ANOVA y algoritmo Relief-F) arrojan resultados muy similares en el ranking de ordenación de la importancia de las variables de diagnóstico. Sin embargo, la técnica RF-RFE ha arrojado diferentes resultados para cada fuente de alimentación:

- Alimentación de red. En este caso, para ambos niveles de carga el número de variables seleccionadas ha coincidido. Sin embargo, para cada conjunto correspondiente a un nivel de carga particular, las variables resultantes son diferentes y únicamente tienen en común el LSH y RSH.
- Alimentación con inversor ABB. Para este tipo de fuente, el deslizamiento juega el mismo papel para ambos niveles de carga.
- Alimentación con inversor Allen Bradley. Para este tipo de alimentación se ha observado que tanto para el nivel de carga NC1 como para NC2 todas las variables del conjunto

de datos han sido seleccionadas como entradas para la etapa de diagnóstico.

- Alimentación con inversor Telemecanique. Con este tipo de alimentación, el número de variables seleccionadas para el NC1 es mucho menor que para el caso NC2.

En general, para el caso NC1 se observa que, a pesar de ser señales correspondientes a un conjunto bastante homogéneo desde el punto de vista estadístico, el deslizamiento ha sido identificada como una variable relevante para la etapa de clasificación. Sin embargo, para el nivel NC2 esta variable no ha sido tan determinante.

Desarrollo de SMOTE para equilibrar conjuntos de datos desequilibrados correspondientes a los diferentes estados del motor.

SMOTE es una técnica muy empleada en otros campos como en el de la ciencia de datos. En esta tesis se ha implementado SMOTE con el objetivo de construir una metodología novedosa que sea útil para realizar un diagnóstico con conjuntos pequeños de datos y clases o estados del motor desequilibrados. SMOTE sobremuestra las observaciones pertenecientes a una clase minoritaria (motor sano) creando muestras sintéticas mediante la aplicación de un enfoque iterativo de búsqueda y selección. Generalmente, cada observación de la clase minoritaria es iterada hasta que el número total de clases se equilibra. El procedimiento de generación de nuevas muestras se lleva a cabo con el algoritmo k -NN.

A diferencia de trabajos anteriores, la inclusión de esta técnica como parte de la metodología permite desarrollar una etapa de diagnóstico automático útil y aplicable a conjuntos de datos donde las observaciones correspondientes al motor sano sobrepasen en número a aquellas correspondientes a cualquier estado de fallo del motor. Se ha comprobado cómo la metodología mejora los resultados de precisión diagnóstica cuando se construye un conjunto de datos de entrenamiento equilibrado aplicando SMOTE. Además, el uso combinado de SMOTE y *AdaBoost* ha demostrado que, en presencia de diferentes tamaños del conjunto de datos (para el mismo IR) y bajo diferentes ratios de desequilibrio, todavía presenta resultados estables.

Construcción del clasificador AdaBoost.

AdaBoost es un meta-algoritmo que ha presentado muchas ventajas ya que es relativamente flexible (puede combinarse con cualquier algoritmo de aprendizaje) y es más sencillo

y fácil de programar que otros algoritmos que requieren una optimización compleja de sus parámetros de ajuste. *AdaBoost* es adaptivo en el sentido de que los clasificadores que se construyen en etapas posteriores son afinados en favor de aquellas observaciones que fueron erróneamente clasificadas anteriormente. Además, tiene la ventaja de que no se requiere conocimiento previo sobre el clasificador débil, y puede proporcionar reglas consistentes básicas tanto para problemas binarios como multiclase. Sin embargo, la principal desventaja que tiene *AdaBoost* es que es sensible al ruido por lo que es necesario partir de un conjunto de datos carente de outliers y con bajo ruido.

A diferencia del algoritmo *Bagging*, donde los conjuntos de observaciones de entrenamiento se forman por re-muestreo, *AdaBoost* se construye a través de una etapa de ajuste de pesos. Esto hace que cada muestra de entrenamiento tenga una probabilidad diferente de ser seleccionada en los sucesivos conjuntos de entrenamiento.

Comparación del clasificador AdaBoost con otras técnicas presentadas en la literatura.

En la literatura se han encontrado muchos trabajos que abordan el diagnóstico de fallos en MI con algoritmos de aprendizaje automático. Por ello, en este trabajo de tesis varios tipos de algoritmos, a parte de *AdaBoost*, han sido considerados: Naive Bayes, K -NN, árboles de decisión basados en el algoritmo *Classification and Regression Trees* (CART), la técnica de *Bootstrap Aggregating* (*Bagging*) y las máquinas de soporte vectorial (SVM) con un *kernel* de base radial (RBF).

Algunos de los clasificadores analizados han sido usados en la literatura y de ahí su elección. Aunque las prestaciones de los clasificadores se encuentran todas en un margen razonable, la principal ventaja que ha presentado *AdaBoost* frente al resto, seguido muy de cerca por la técnica de *Bagging*, es que presenta muy buenas prestaciones en un amplio número de casos sin la necesidad de entrenar sus parámetros de ajuste de nuevo. Este hecho se ha visto comprobado tanto para relaciones de desequilibrio de 2, como de 5 y de 10. Sin embargo, el algoritmo SVM ha requerido una fase de ajuste compleja de sus parámetros para cada uno de los casos de estudio considerados.

Validación de la metodología. Evaluación de las prestaciones de un clasificador.

Como ha sido explicado, la forma de evaluar un clasificador es determinante a la hora de valorar sus prestaciones. En la parte final del Capítulo 3 se hizo una revisión de las contribuciones dentro del área del aprendizaje estadístico sobre las formas de evaluar los clasificadores empleados en aprendizaje supervisado. La elección adecuada de las métricas para evaluar las prestaciones de una comparación de clasificadores es fundamental a la hora de establecer el dominio particular de alguno de ellos. En este trabajo, se han empleado métricas que indican el comportamiento del clasificador sobre cada clase. Por otro lado, también se revisó que el método de estimación del error tiene un papel fundamental tanto en la compensación sesgo-varianza de la estimación como en la estabilidad de las predicciones. Por ello, métodos como el de Resustitución y *Hold-out* fueron descartados. Finalmente, el uso correcto de las pruebas estadísticas permite confirmar, con un cierto nivel de confianza, si el comportamiento del clasificador es debido a su capacidad predictiva o si los resultados de rendimiento que obtuvo se deben al azar.

6.2. Listado de publicaciones que acompañan a esta tesis.

En el momento de edición de la versión actual de la presente tesis los productos publicados han sido los siguientes:

6.2.1. Artículos publicados.

- **Ignacio Martín–Díaz**, Daniel Morinigo–Sotelo, Oscar Duque–Perez, Rene J. Romero–Troncoso, “Advances in Classifier Evaluation: Novel Insights for an Electric Data–Driven Motor Diagnosis” ,IEEE Access, Vol. 4, pp. 7028-7038, Oct. 2016, DOI: 10.1109/ACCESS.2016.2622679.
- **Ignacio Martín–Díaz**, Daniel Morinigo–Sotelo, Oscar Duque–Perez, Rene J. Romero–Troncoso, “Early fault detection in induction motors using AdaBoost with imbalanced small data and optimized sampling” ,IEEE Transactions on Industry Applications, vol. 53, no. 3, pp.3066-3075, May/Jun. 2017, DOI: 10.1109/TIA.2016.2618756.
- **I. Martín–Díaz**, D. Morinigo–Sotelo, O. Duque–Perez, P.A. Arredondo–Delgado, D. Camarena–Martinez, R. J. Romero–Troncoso, “Analysis of various inverters feeding induction motors with incipient rotor fault using high–resolution spectral analysis”

Elsevier Electric Power Systems Research, Vol. 152, Nov. 2017, Pags. 18-26. DOI: 10.1016/j.epsr.2017.06.021

- **I. Martín–Díaz**, D. Morinigo–Sotelo, O. Duque–Perez, A. Garcia–Perez, D. Camarena–Martinez, R. J. Romero–Troncoso, “High–resolution Spectral Analysis for Fault Detection on Induction Motors fed by Variable–speed Drives” ,NISCAIR-CSIR, Journal of Scientific & Industrial Research,Vol. 76, Sep. 2017, Pags. 545-549.

6.2.2. Ponencias en congresos internacionales.

- **Ignacio Martín–Díaz**, Oscar Duque–Perez, Rene J. Romero–Troncoso, Daniel Morinigo–Sotelo, “Supervised Diagnosis of Induction Motor Faults: A Proposed Methodology for an Improved Performance Evaluation” SDEMPED 2015, pp. 359-365, DOI: 10.1109/DEMPEP.2015.7303715
- **Ignacio Martín–Díaz**, Daniel Morinigo–Sotelo, Oscar Duque–Perez, Rene J. Romero–Troncoso, “Evaluation of intelligent approaches for motor diagnosis under changing operational conditions” SDEMPED 2017, pp. 65-71, DOI: 10.1109/DEMPEP.2017.8062335.

6.3. Prospectivas.

Aunque una tesis doctoral inicia con un protocolo de tesis donde se desarrolla un plan de investigación estableciendo los objetivos que ha de perseguir la tesis, ésta no acaba con su defensa tras finalizar el doctorado. Muchas prospectivas tanto tecnológicas como personales surgen durante este trabajo doctoral.

6.3.1. Prospectiva tecnológica.

Las prospectivas tecnológicas que abre esta tesis como continuación a la línea de investigación seguida se plantean desde varias perspectivas:

1. *Monitorización de la condición.*

- Aunque en esta tesis se ha atendido de forma exclusiva el fallo mecánico de la rotura incipiente de una barra en el rotor, permanece abierta la aplicación y comprobación de las técnicas estudiadas para otros tipos de anomalías como fallos tempranos en rodamientos o incluso en el estátor.

- Es cierto que MCSA presenta muchas ventajas respecto a otras magnitudes para monitorizar el estado de fallo en la jaula del rotor. Sin embargo, se puede ampliar el estudio a otros tipos de señales para la monitorización del motor como el análisis del flujo magnético o a través de una combinación de magnitudes.

2. *Técnicas de detección.*

- Una de las limitaciones de la metodología propuesta para detectar el fallo temprano en alimentación por inversor es que requiere combinar dos pasos. En primer lugar, se requiere aplicar MUSIC para identificar las frecuencias de fallo; y en segundo lugar requiere aplicar la FFT para cuantificar el fallo. Una de las puertas que abre esta tesis es la de conseguir la localización de frecuencias y la estimación de la severidad del fallo en un solo paso. Por ello, se propone la aplicación de técnicas como RootMUSIC o ESPRIT para conseguirlo.
- El empleo de técnicas de análisis espectral para extraer patrones en el estado estacionario permite cuantificar varios estados intermedios al fallo de rotura de una barra en el rotor con alimentación de inversor. Sin embargo, la obtención de patrones en el dominio tiempo-frecuencia puede permitir desarrollar herramientas de diagnóstico que empleen la información de los cambios de régimen del motor, ya sea en un arranque, parada o cambio en el nivel de carga para ver evolucionar y cuantificar las frecuencias de fallo. Desde este punto de vista, se puede plantear extraer características de los espectrogramas con elevada capacidad discriminante para su empleo en diagnóstico automático teniendo en cuenta la influencia del tipo de alimentación.

3. *Técnicas de diagnóstico.* Desde el punto de vista del diagnóstico, se puede continuar trabajando en los siguientes aspectos:

- Implementación en hardware, como por ejemplo FPGA, de la herramienta de diagnóstico propuesta que permita hacer diagnósticos en línea de fallos en el rotor aprovechando el análisis realizado en esta tesis.
- Optimizar el conjunto de características considerando tanto aquellas obtenidas en el estado estacionario como aquellas pertenecientes a señales transitorias para lograr una mayor eficiencia de diagnóstico con datos desequilibrados.
- En esta tesis se presentó un estudio muy centrado en cada tipo de alimentación del motor y en dos niveles de carga. Se puede mejorar la robustez del clasificador

en cuanto al origen de los datos de entrenamiento a través de la construcción de un clasificador híbrido capaz de establecer sus reglas de decisión en función de las características de los datos (Nivel de carga, etc.).

4. *Planificación del mantenimiento predictivo.*

- Uno de los objetivos del mantenimiento predictivo es su eficacia. Sin embargo, dependiendo de la importancia del motor, el ajuste del punto de corte (probabilidad de asignación a cada clase) que haga que el clasificador obtenga las mejores prestaciones puede depender mucho de este aspecto. Por lo tanto, se puede ampliar el estudio de la herramienta de diagnóstico ateniendo a los costes o implicaciones que pueda tener la ocurrencia de un FP o FN. En otros campos de la literatura, existen algunas técnicas denominadas técnicas de aprendizaje sensible al coste que estudian la influencia de los costes de una mala clasificación donde lo que se pretende es minimizar el coste total en vez de maximizar el número de aciertos del clasificador.

6.3.2. Prospectiva personal.

El periodo doctoral, el cual culmina al cabo de tres años, hace que desarrolle una visión particular sobre este proceso de formación. En los inicios de la tesis, aprendí a planificar el desarrollo experimental teniendo en cuenta los aspectos más críticos para llevar a cabo el diseño de experimentos. Además, también aprendí a analizar, estudiar, replicar y criticar las investigaciones de otros colegas del área. Durante este periodo he aprendido a buscar información muy específica del área, la cual me sirve para desarrollar y mantenerme actualizado del trabajo de los grupos de investigación más activos en el campo del diagnóstico de máquinas eléctricas rotativas. Además, este proceso de doctorado me ha permitido profundizar mis conocimientos incluyendo técnicas y conceptos de otras áreas con aplicación de interés en el diagnóstico automático e inteligente de fallos. Durante este proceso aprendí a ver las limitaciones de las investigaciones publicadas y en proceso de publicación las cuales me permiten apreciar las necesidades presentes en el área para dar cabida a futuros trabajos y desarrollos experimentales. Tras este periodo de formación me veo con la capacidad de desarrollar y dirigir proyectos de investigación original gracias a las habilidades obtenidas durante este proceso de formación doctoral.

Capítulo 7

Conclusions and contributions

This final chapter of the thesis presents the conclusions and contributions derived from the results obtained from the application of the proposed diagnosis methodologies. The publications to which this thesis has given rise are indicated below. Finally, the chapter ends with the opened foresights after completing this process of doctoral training.

7.1. Technical conclusions of the work

The initial objectives and hypotheses have determined the steps of each of the stages of the developed methodologies. The investigation and proposal of solutions for the generation of synthetic observations to balance the training dataset for being able to induce more efficient classifiers for the diagnosis of mechanical rotor faults have been the main focus of this thesis. In order to achieve this objective, the first step has been to identify the main factors that determine the performance of an automatic rotor fault diagnosis system based on the analysis of the motor power supply. Therefore, as explained in the document, the stages of data acquisition, feature extraction and selection, and classifier induction have represented the main aspects in which this thesis has been focused. It should be noted that the investigations and contributions related to the proposed diagnosis scheme have been performed under significant requirements for the diagnosis tool under study, which has consisted of the following steps.

Development of a methodology for the location and quantification of incipient faults in steady state

Through the review of the background, the problem of locating the characteristic fault frequencies when an induction motor (IM) is fed by an inverter has been thoroughly investigated.

A methodology has been developed to identify and quantify incipient rotor faults using the stator current of an IM. First of all, it is a question of locating the fault frequency through the MUSIC transform by choosing the right order for the type of power supply in question. Subsequently, the FFT quantifies the severity of the fault through the amplitudes of the characteristic harmonics of a rotor bar breakage. For this, it was observed that at least an acquisition time of 10 s is necessary to have a proper frequency resolution.

It has been observed that an incorrect choice of the MUSIC order may produce false results. Hence, the need arose to propose a technique for selecting the order of MUSIC based on the choice of order statistics. To this end, signal sets obtained in the laboratory were used. In addition, it has been verified that for certain types of feeding, as is the case of TM, where the intrinsic floor noise is very high, not even MUSIC can identify the spectral fault signatures when the IM develops a half broken rotor bar fault. The following has also been observed:

- For fault detection with a completely broken bar, choosing a single MUSIC order is sufficient. However, this is not the case for the detection of incipient faults where more information about the signal is needed. Therefore, three orders of MUSIC, to help better discriminate between the healthy state and the R3 IM condition, were chosen.
- For all the types of power supply considered in this thesis, the R5 severity can be detected with a single order of MUSIC even for low-medium load.
- The greatest difficulty in detecting the severity of half broken rotor bar (R3) arises for signals corresponding to an IM of the described characteristics operating with a low-medium load (NC1).

The main advantage of MUSIC, to identify the fault components, is that it does not require the use of additional sensors to calculate the speed. However, it is necessary to take into account the limitations of the presented method, such as the influence of the power supply and the load level, to obtain the fault frequencies, and therefore, for its application in the

methodology of automatic diagnosis.

Application of methods for the feature selection with different power sources.

Within the realized revision it is appreciated that there are several techniques of feature reduction and selection that are more or less appropriate according to the characteristics of the dataset. On the other hand, despite the advantages of the feature reduction techniques, they have the drawback that the physical meaning of the final variables, to which the original set is reduced, is lost. Therefore, the objective of the feature selection techniques applied in this thesis, apart from analyzing which variables are correlated and how is their relation with the rest, is to analyze the degree of relevance of each of them in terms of classification performance. In this thesis, contributions corresponding to both ranking approaches (filtering methods) and a novel approach where it is determined which variables are optimal for the classification stage have been developed. It has been proposed the combined application of the *Random Forest* algorithm with the *Recursive Feature Elimination* (RFE) technique to determine the number and identity of the most relevant variables for each case studied. The results of the feature selection stage have shown that the three filtering techniques used (*Information Gain*, *ANOVA* and *Relief-F* algorithm) show very similar results in the ranking of the importance of the diagnostic variables. However, the RF-RFE technique has yielded different results for each power source:

- Line-fed case. In this case, for both load levels the number of selected variables has matched. However, for each set corresponding to a particular load level, the resulting variables are different and only have in common the LSH and RSH.
- Power supply with ABB inverter. For this type of supply, the slip plays the same role for both load levels.
- Power supply with Allen Bradley inverter. For this type of feeding it has been observed that for both the NC1 and NC2 load levels all the variables in the dataset have been selected as inputs for the diagnosis step.
- Power supply with Telemecanique inverter. With this type of feeding, the number of variables selected for NC1 is much lower than for NC2.

In general, for case NC1, it is observed that, despite being signals corresponding to a sufficiently homogeneous set from the statistical point of view, the slip has been identified as

a relevant variable for the classification stage. However, for the NC2 level this variable has not been as determinant.

Development of SMOTE to balance imbalanced datasets corresponding to different motor states.

SMOTE is a technique widely used in other fields such as data science. In this thesis, SMOTE has been implemented with the objective of constructing a novel methodology that is useful to make a diagnosis with small datasets of imbalanced classes (or motor states). SMOTE oversamples observations belonging to a minority class (healthy motor) by creating synthetic samples by applying an iterative search and selection approach. Generally, each observation of the minority class is iterated until the total number of classes is balanced. The procedure for generating new samples is carried out with the k -NN algorithm.

Unlike previous studies, the inclusion of this technique as part of this methodology allows the development of a useful automatic diagnosis stage applicable to datasets where the observations corresponding to the healthy motor outnumber those corresponding to any faulty state of the motor. It has been proven how this methodology improves the results of diagnostic accuracy when building a balanced training data set by applying SMOTE. In addition, the combined use of SMOTE and *AdaBoost* has shown that, in the presence of different sizes of the dataset (for the same IR) and under different imbalance ratios, it still presents stable results.

Construction of the *AdaBoost* classifier.

AdaBoost is a meta-algorithm that has many advantages since it is relatively flexible (can be combined with any learning algorithm) and is simpler and easier to program than other algorithms that require a complex optimization of their tuning parameters. *AdaBoost* is adaptive in the sense that the classifiers that are constructed in later stages are tuned in favor of those observations that were erroneously classified previously. In addition, it has the advantage that prior knowledge about the weak classifier is not required, and can provide basic consistent rules for both binary and multiclass problems. Nonetheless, the main disadvantage that *AdaBoost* has is that it is sensitive to noise so it is necessary to start from a dataset lacking outliers and with low noise.

Unlike the *Bagging* algorithm, where the training observation sets are formed by re-sampling, *AdaBoost* is built through a weight adjustment step. This makes each training sample have a different probability of being selected in successive training sets.

Comparison of *AdaBoost* classifier with other techniques presented in the literature.

In the literature, many studies have been found that address the diagnosis of IM failures with automatic learning algorithms. In this thesis, several types of algorithms, besides AdaBoost, have been considered: *Naive Bayes*, *K-NN*, *decision trees* based on the Classification and Regression Trees (CART) algorithm, the *Bootstrap Aggregating technique* (Bagging) and *Support Vector Machines* (SVM) with a radial base kernel (RBF).

Some of the classifiers analyzed have been used in the literature and hence their choice. Although the performance of the classifiers seems to stay within a reasonable range, the main advantage that AdaBoost has against the rest, closely followed by the technique of *Bagging*, is that it presents very good performance in a large number of cases without the need of training their adjustment parameters again. This fact has been verified for the imbalance ratios of 2, 5 and 10. However, the SVM algorithm has required a complex adjustment phase of its parameters for each case study considered.

Validation of the classification methodology. Evaluation of the performance of a classifier.

As has been explained, the way to evaluate a classifier is decisive when assessing its performance. In the final part of Chapter 3, a review of the contributions within the area of statistical learning on ways to evaluate classifiers used in supervised learning was made. The proper choice of metrics to evaluate the performance of a classifier comparison is fundamental when establishing the particular domain of some of them. In this work, metrics that indicate the behavior of the classifier over each class have been used. On the other hand, it was also revised that the error estimation method has a fundamental role in the bias-variance trade-off and in the stability of the predictions. Therefore, methods such as *Resubstitution* and *Hold-out* were discarded. Finally, the correct use of the statistical tests allows to confirm, with a certain level of confidence, if the classifier's behavior is due to its predictive ability or

if the performance results obtained are due to chance.

7.2. List of publications that accompany this thesis.

At the time of editing the current version, the scientific products published have been the following:

7.2.1. JCR peer-review publications

- **Ignacio Martín–Díaz**, Daniel Morinigo–Sotelo, Oscar Duque–Perez, Rene J. Romero–Troncoso, “Advances in Classifier Evaluation: Novel Insights for an Electric Data–Driven Motor Diagnosis” ,IEEE Access, Vol. 4, pp. 7028-7038, Oct. 2016, DOI: 10.1109/ACCESS.2016.2622679.
- **Ignacio Martín–Díaz**, Daniel Morinigo–Sotelo, Oscar Duque–Perez, Rene J. Romero–Troncoso, “Early fault detection in induction motors using AdaBoost with imbalanced small data and optimized sampling” ,IEEE Transaccions on Industry Applications, vol. 53, no. 3, pp.3066-3075, May/Jun. 2017, DOI: 10.1109/TIA.2016.2618756.
- **I. Martín–Díaz**, D. Morinigo–Sotelo, O. Duque–Perez, P.A. Arredondo–Delgado, D. Camarena–Martinez, R. J. Romero–Troncoso, “Analysis of various inverters feeding induction motors with incipient rotor fault using high–resolution spectral analysis” Elsevier Electric Power Systems Research, Vol. 152, Nov. 2017, Pags. 18-26. DOI: 10.1016/j.epsr.2017.06.021
- **I. Martín–Díaz**, D. Morinigo–Sotelo, O. Duque–Perez, A. Garcia–Perez, D. Camarena– Martinez, R. J. Romero–Troncoso, “High–resolution Spectral Analysis for Fault Detection on Induction Motors fed by Variable–speed Drives” ,NISCAIR–CSIR, Journal of Scientific & Industrial Research, Vol. 76, Sep. 2017, Pags. 545-549.

7.2.2. Oral presentations and peer-review publications in International Conferences

- **Ignacio Martín–Díaz**, Oscar Duque–Perez, Rene J. Romero–Troncoso, Daniel Morinigo–Sotelo, “Supervised Diagnosis of Induction Motor Faults: A Proposed Methodology for

an Improved Performance Evaluation” SDEMPED 2015, pp. 359-365, DOI: 10.1109/DEM-PED.2015.

7303715

- **Ignacio Martín–Díaz**, Daniel Morinigo–Sotelo, Oscar Duque–Perez, Rene J. Romero–Troncoso, “Evaluation of intelligent approaches for motor diagnosis under changing operational conditions” SDEMPED 2017, pp. 65-71, DOI: 10.1109/DEM-PED.2017.8062335.

7.3. Foresights

Although a doctoral thesis begins with a thesis protocol in which a research plan is developed, establishing the objectives to be pursued by the thesis, it does not end with its defense after finishing the doctorate. Many technological and personal perspectives arise during this doctoral work.

7.3.1. Technological foresight

The technological foresight that this thesis opens, as a continuation of the research line followed, is considered from several perspectives:

1. *Condition monitoring*

- Although this thesis deals exclusively with the mechanical rotor bar breakage, the application and testing of the techniques studied for other types of anomalies such as early faults in bearings or even in the stator remain open.
- It is true that MCSA has many advantages over other magnitudes for the condition monitoring of faults in the rotor cage. However, the study can be extended to other types of signals for this monitoring such as magnetic flux analysis or through a combination of magnitudes.

2. *Detection techniques*

- One of the limitations of the proposed methodology for detecting early failure in inverter powered IMs is that it requires combining two steps. First, MUSIC is required to locate the fault frequencies; and second, FFT is used to quantify the severity of the fault. This thesis opens the doors to obtain the frequency location and the estimation of the fault severity in a single step. For this reason, the application of techniques such as RootMUSIC or ESPRIT is proposed to achieve it.

- The use of spectral analysis techniques in the stationary regime allows the extraction of patterns for an incipient rotor fault diagnosis for the case of an inverter-fed IM. However, obtaining patterns in the time-frequency domain may allow the diagnosis under changes in the IM regime of operation as at startup or stop, to see the evolution and to quantify the fault frequencies. From this point of view, it is possible to consider extracting specific features from spectrograms with a high discriminating capacity for their use in the automatic diagnosis, taking into account the influence of the type of motor feeding.
3. *Diagnosis techniques* From a diagnosis point of view, we can continue to work on the following aspects:
- Hardware implementation, such as FPGA, of the proposed diagnostic tool that allows on-line diagnosis of rotor faults using the analysis carried out in this thesis.
 - Optimize the set of characteristics considering both those obtained in the stationary state and those concerning to transient signals to achieve greater diagnosis efficiency with unbalanced data.
 - In this thesis, a study was presented that focused on each type of IM power supply and on two load levels. The robustness of the classifier in terms of the origin of training data can be improved by building a hybrid classifier capable of establishing its decision rules based on the characteristics of the data (load level, etc.).
4. *Predictive maintenance planning*
- One of the objectives of predictive maintenance is its effectiveness. However, depending on the importance of the IM, the adjustment of the cut-off point (probability of assignment to each class) that will make the classifier get the best performance can depend a lot on this aspect. Therefore, the study of the diagnosis tool can be extended taking into account the costs or implications that the occurrence of a FP or FN may have. In other fields of the literature, there are some techniques known as cost-sensitive learning techniques that study the influence of the costs of misclassification where what is desired is to minimize the total cost rather than maximize the number of successes of the classifier.

7.3.2. Personal foresight

The doctoral period, which ends after three years, allows me to develop a particular vision of this training process. In the beginning of the thesis, I learned how to plan experimental tests taking into account the most critical aspects to carry out the design of experiments. In addition, I also learned to analyze, study, replicate and critique the research of other colleagues in the area. During this period, I have learned to look up very specific information in the area, which helps me to develop and keep up to date with the work of the most active research groups in the field of the diagnosis of rotating electrical machines. In addition, this doctoral process has allowed me to deepen my knowledge, including techniques and concepts from other areas with application of interest in automatic and intelligent fault diagnosis. During this process I learned to see the limitations of the published researches and to critically analyze those publications under review which allow me to appreciate the needs present in the area. After this period of training, I am able to develop and conduct original research projects thanks to the skills obtained during this doctoral training process.

Apéndice A

Equipos empleados en el desarrollo experimental.

A.1. Motor de inducción.

El motor de inducción forma el equipo principal del banco de pruebas ya que es el elemento a ensayar. Este tipo de motor y, particularmente, su versión de baja potencia es muy utilizado en industrias con un número elevado de horas de operación al año. Esta circunstancia, permite que pueda ser usado para desarrollar el sistema de diagnóstico automático propuesto y validarlo. El motor utilizado es asíncrono, con rotor de jaula de ardilla, del fabricante Siemens, que se puede ver en la Fig. A.1. En todos los ensayos realizados el estátor se conectó en configuración de estrella.

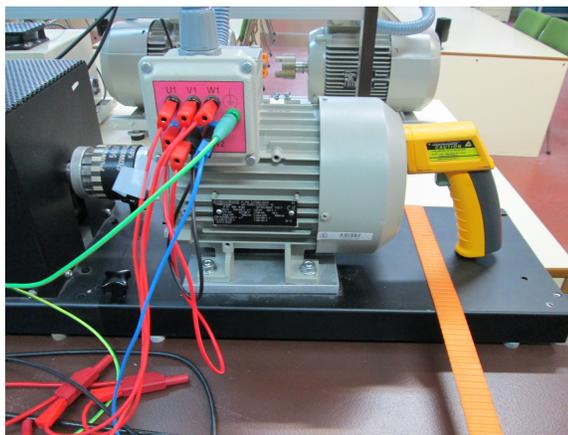


Figura A.1: Motor ensayado.

Las especificaciones técnicas del motor son las siguientes:

- Potencia nominal: 0,75 kW
- Tensión nominal: 2x230/400 V
- Conexión del motor: Estrella
- Frecuencia nominal: 50 Hz
- Corriente nominal: 1.9 A
- Número de pares de polos: 2
- Número de barras del rotor: 28
- Velocidad nominal: 1395 rpm
- Denominación: 3 Mot 1LA7083-4AA10
- Eficiencia: IE1
- Índice de protección: IP55
- Tamaño: 80M IM B3
- Clase térmica: ThcL F
- Factor de servicio: 1,1

A.2. Fuentes de suministro del motor.

A continuación se describen los tipos de suministro empleado en las pruebas de laboratorio.

A.2.1. Inversores

Los inversores empleados en el desarrollo experimental son los siguientes:

- Inversor ABB modelo ACS355.

Las especificaciones técnicas del variador ABB ACS355 son las siguientes:

- Potencia nominal: 0.37 – 7.5 kW

- Tensión de entrada: 3x380/480 V
- Tensión de salida: 0-460 V
- Corriente nominal: 7.5 A
- Frecuencia de entrada: 48 – 63 Hz
- Frecuencia de salida: 0 – 600 Hz
- Sobrecarga temporal (60 s): 9 A
- Denominación: ACS355-01X-02A4-2
- Índice de protección: IP66



Figura A.2: Inversor ABB modelo ACS355.

- Inversor Allen Bradley modelo PowerFlex 40.

Las especificaciones técnicas del variador PowerFlex 40 de Allen Bradley son:

- Potencia nominal: 0.75 kW
- Tensión de entrada: 3x380 /480 V
- Tensión de salida: 0-460 V
- Corriente nominal: 7.5 A
- Corriente de salida máx. de salida en continuo: 6 A
- Frecuencia de entrada: 48 – 63 Hz
- Frecuencia de salida: 0 – 400 Hz
- Sobrecarga temporal (60 s): 9 A
- Denominación: 22B-D6P0N104
- Número de serie: BD6P0N0W8500204



Figura A.3: Inversor Allen Bradley modelo PowerFlex 40.

- Índice de protección: IP20
- Inversor WEG modelo CFW-11.
Las especificaciones técnicas del variador WEG CFW-11 son:
 - Potencia nominal: 11 a 160 kW
 - Tensión de entrada: 3x380/480 V
 - Tensión de salida: 0-460 V
 - Corriente nominal: 7.5 A
 - Corriente de salida máx. de salida en continuo:
 - Frecuencia de entrada: 50/60 Hz
 - Frecuencia de salida: 0 –300Hz
 - Sobrecarga temporal (60 s): 9 A
 - Índice de protección: IP20
- Inversor Siemens modelo Micromaster 420.
Las especificaciones técnicas del variador Siemens MicroMaster 420 son:
 - Potencia nominal: 4 kW
 - Tensión de entrada: 3x380/480 V
 - Tensión de salida: 0-Tensión de Entrada V
 - Frecuencia de entrada: 47-63 Hz
 - Frecuencia de salida: 0-650 Hz
 - Corriente de salida máx. de salida en continuo: 10,2 A



Figura A.4: Inversor WEG modelo CFW-11.

- Denominación: 6SE6420-2UD24-0BA1
- Número de serie: XAW902-006579
- Índice de protección: IP20



Figura A.5: Inversor Siemens modelo Micromaster 420.

- Inversor Telemecanique modelo Altivar 66.
Las especificaciones técnicas del variador telemecanique Altivar 66 son:

- Potencia nominal: 2.2 kW
- Tensión de entrada: $3 \times 400 \text{ V} - 15\%$ a $460 \text{ V} + 15\%$
- Tensión de salida: 0–460 V
- Corriente nominal: 9 A
- Corriente de salida máx. de salida en continuo: 5.8 A
- Frecuencia de entrada: $50/60 \text{ Hz} \pm 5\%$
- Frecuencia de salida: 0.1 – 400 Hz
- Sobrecarga temporal (60 s): 5 A
- Denominación: ATV-66U41N4
- Índice de protección: IP20



Figura A.6: Inversor Telemecanique modelo Altivar 66.

A.2.2. Alimentación de red.

Además de la alimentación por inversor, el motor ha sido alimentado por medio de una conexión directa a la red eléctrica, proporcionando una energía de las siguientes características: 50 Hz, 400 V entre fases, 230 V tensión fase neutro.

A.3. Freno y unidad de control.

Para cargar el motor y por tanto, poder aplicar un par resistente, se ha usado un freno de polvo magnético de Lucas-Nulle (Fig. A.7). Para poder regular y hacer un ajuste fino del par resistente, el freno va acompañado de una unidad de control, también de Lucas-Nulle (Fig. A.7). Para la visualización continua de la velocidad de giro y el par resistente ejercido por el freno, éste incorpora unos indicadores de medida.



Figura A.7: Freno conectado al motor y unidad de control.

Las especificaciones técnicas del freno de polvo magnético Lucas-Nulle son:

- Potencia nominal: 1 kW
- Tensión de entrada: 230 V
- Frecuencia de entrada: 50 Hz
- Par resistente: 0 - 25 Nm
- Velocidad de giro: 0 - 6000 rpm
- Denominación: SE 2662-5R

Las especificaciones técnicas de la unidad de control de Lucas-Nulle son las siguientes:

- Tensión de entrada: 230 V
- Frecuencia de entrada: 50 Hz
- Denominación: SO 3213-7S

A.4. Sensores

El registro oportuno de las magnitudes monitorizadas se ha realizado por medio de los siguientes transductores y sensores. Los sensores, van equipados con PCB, y han sido mon-

tados sobre dos placas de diseño propio construidas en el laboratorio de Redes Eléctricas de la Universidad de Valladolid. Los sensores se muestran en la Fig. A.8.



Figura A.8: Tarjetas dedicadas con los transductores de efecto Hall (tensión y de corriente).

A.4.1. Transductores de corriente.

Dos de los transductores de corriente utilizados son de Honeywell y se ha empleado uno más de LEM; todos ellos de efecto Hall.



Figura A.9: Transductor de corriente de Honeywell.

Las especificaciones técnicas del transductor de corriente de Honeywell son:

- 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: $\pm 15V_{DC}$.
- Consumo de corriente: 10 (@ $\pm 15V$) + Corriente secundaria mA.



Figura A.10: Transductor de corriente de LEM.

- Ratio de conversión: 2500:1000
- Precisión: $\pm 0,5\%$
- Tiempo de respuesta: $1\mu s$
- Empaquetamiento: PCB

Las especificaciones técnicas del transductor de corriente de LEM son:

- Denominación: LA 25-NP
- Corriente primaria nominal: 25 mA (eficaces)
- Rango de medida: $0 \pm 36A$
- Corriente secundaria nominal: 25 mA (eficaces)
- Tensión de alimentación: $\pm 15V$
- Consumo de corriente: 10+ Corriente secundaria mA.
- Precisión: $\pm 0.5\%$
- Tiempo de respuesta: $1\mu s$
- Ancho de Banda (-1 dB): DC 150 kHz
- Empaquetamiento: PCB

A.4.2. Transductores de tensión.

La medida de la tensión ha sido realizada con un transductor de efecto Hall de LEM (Fig. A.11). En el lado primario del sensor se conectan los terminales objeto de medición. La conexión se realiza a través de una resistencia externa, para hacer pasar una corriente del orden de mA por el primario del sensor. La máxima precisión se obtiene cuando esta corriente a los 10 mA. La resistencia externa ha sido calculada para que a la máxima tensión de la medición, la corriente del primario del sensor sea precisamente esos 10 mA. Para tales condiciones, la precisión es de $\pm 0.8\%$ de la tensión de entrada. La corriente secundaria de salida del sensor, la cual es proporcional a la tensión de entrada se hace circular por otra resistencia para efectuar la medida de la tensión.

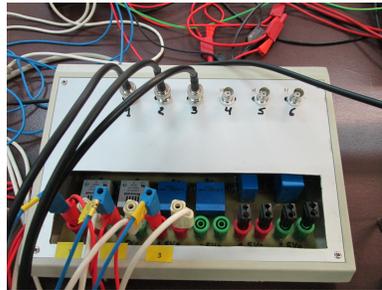


Figura A.11: Transductores de tensión.

Las especificaciones técnicas del transductor de tensión son:

- Corriente primaria nominal: 10 mA (eficaces)
- Tensión primaria (AC y DC): 10-500 V.
- Corriente secundaria nominal: 25 mA (eficaces)
- Tensión de alimentación: $\pm 12 - 15V$
- Consumo de corriente: $10(@ \pm 15V) +$ Corriente secundaria mA.
- Ratio de conversión: 2500 : 1000
- Precisión a la corriente primaria nominal y $25^\circ C$ de temperatura:
 - @ $\pm 12V \dots 15V$: $\pm 0,9\%$
 - @ $\pm 15V(\pm 5\%)$: $\pm 0,8\%$

- Tiempo de respuesta a un escalón del 90 % de la corriente primaria nominal: $40\mu s$
- Ancho de Banda (-1 dB): DC ... 150 kHz
- Empaquetamiento: PCB

A.5. Sistema de adquisición de datos.

El sistema de adquisición de datos es del fabricante National Instruments (Fig. A.12), de tipo modular compuesto por los siguientes elementos:

- Chasis compacto: NI cDAQ-9174. Este chasis permite la conexión de hasta 4 módulos de E/S.
- Módulo de adquisición: NI 9215.

Las especificaciones técnicas del Chasis NI cDAQ-9174 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

Las especificaciones técnicas del Módulo NI 9215 se citan a continuación:

- Denominación: 779011-01
- Número de serie: 199269A-1L 14C7DAA
- Tipos de Medida: Voltaje



Figura A.12: Sistema de adquisición de datos de NI.

- 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

A.6. Ordenador y software empleado.

El sistema de adquisición de datos se conecta por medio de un USB 2.0 a un ordenador portátil (Fig. A.13), modelo 6717s Lenovo. Dispone de un procesador Intel core i7, con memoria RAM de 12GB. El sistema operativo es Windows 10 de 64 bits. El software empleado

para la adquisición es MATLAB© versión R2010. Por medio de este software y con la Toolbox de Signal Processing se realizaron los cálculos de la FFT y MUSIC así como los estadísticos de la señal de corriente. La captura de los ensayos es guardada en un archivo “.mat” para su posterior procesamiento. Además, se utilizó el software libre para análisis estadístico conocido como “R” [182].

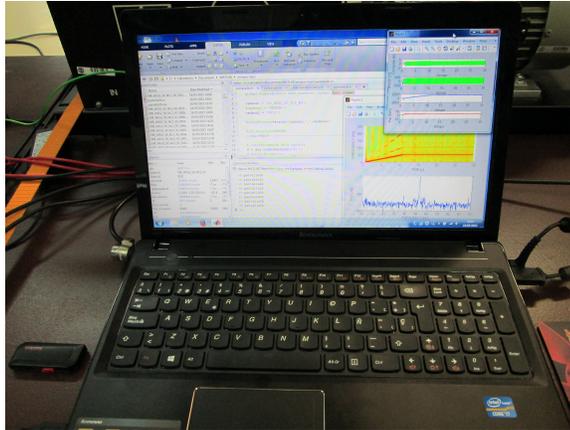


Figura A.13: Ordenador portátil empleado.

Apéndice B

Características de los ensayos realizados.

A continuación (Figs. B.1-B.10) se presentan varios diagramas Boxplots que sirven para observar la homogeneidad de cada modalidad de ensayo.

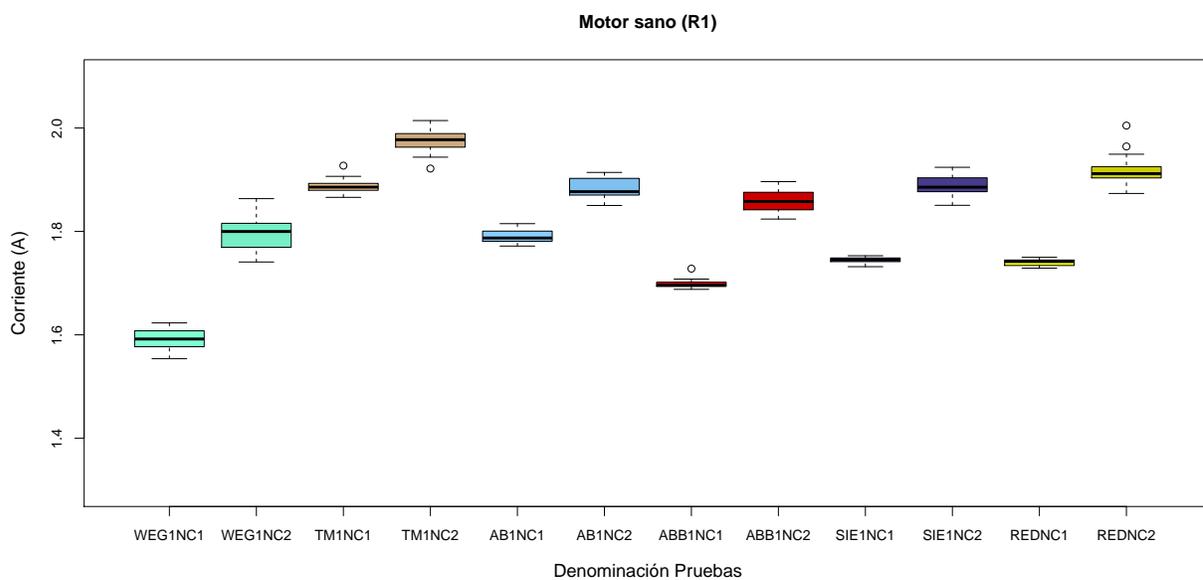


Figura B.1: Boxplots de las pruebas con los valores de corriente. Motor sano (R1).

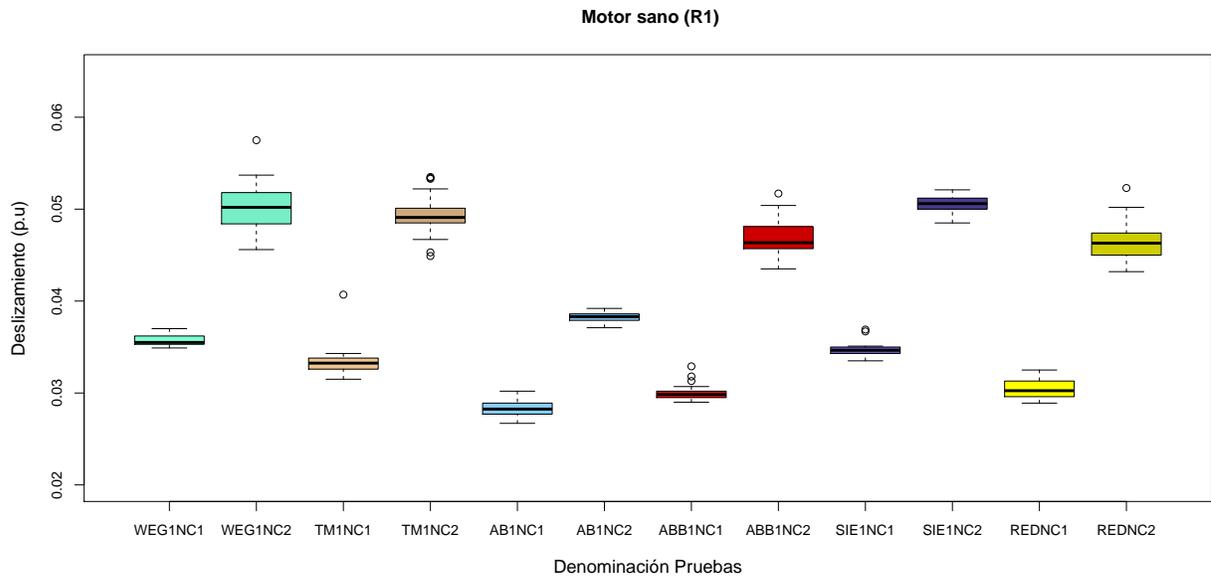


Figura B.2: Boxplots de las pruebas con los valores de deslizamiento. Motor sano (R1).

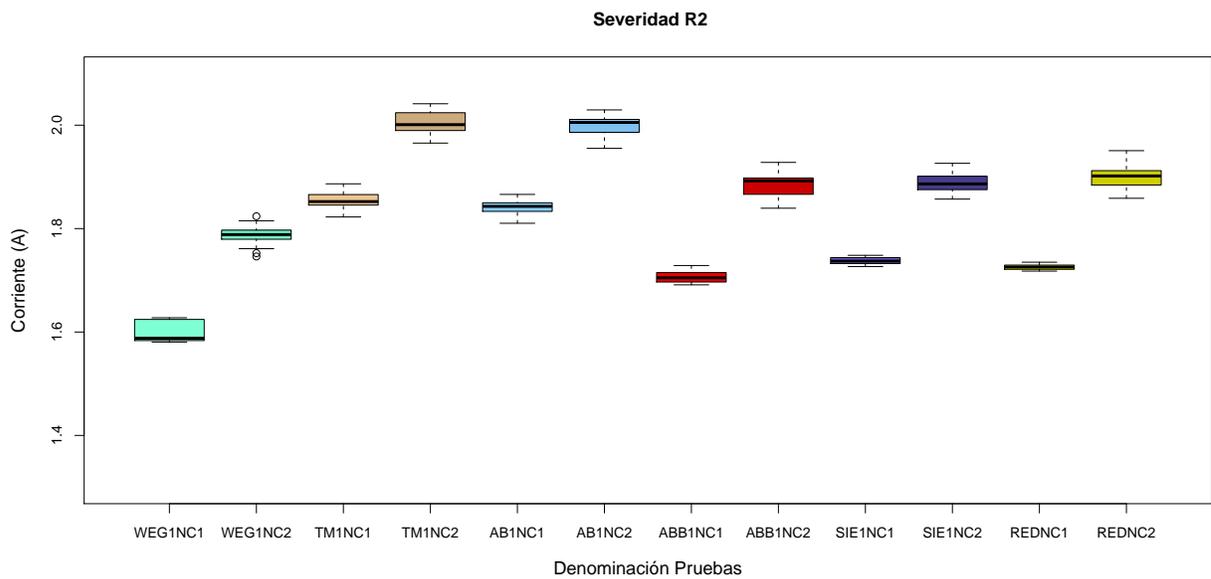


Figura B.3: Boxplots de las pruebas con los valores de corriente. Severidad R2.

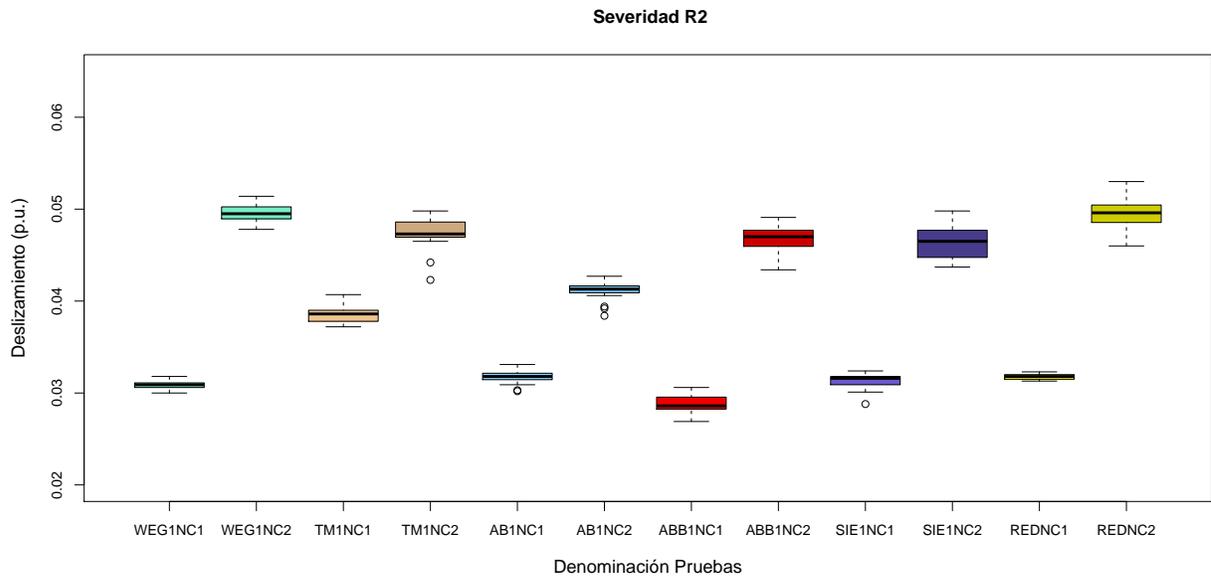


Figura B.4: Boxplots de las pruebas con los valores de deslizamiento. Severidad R2.

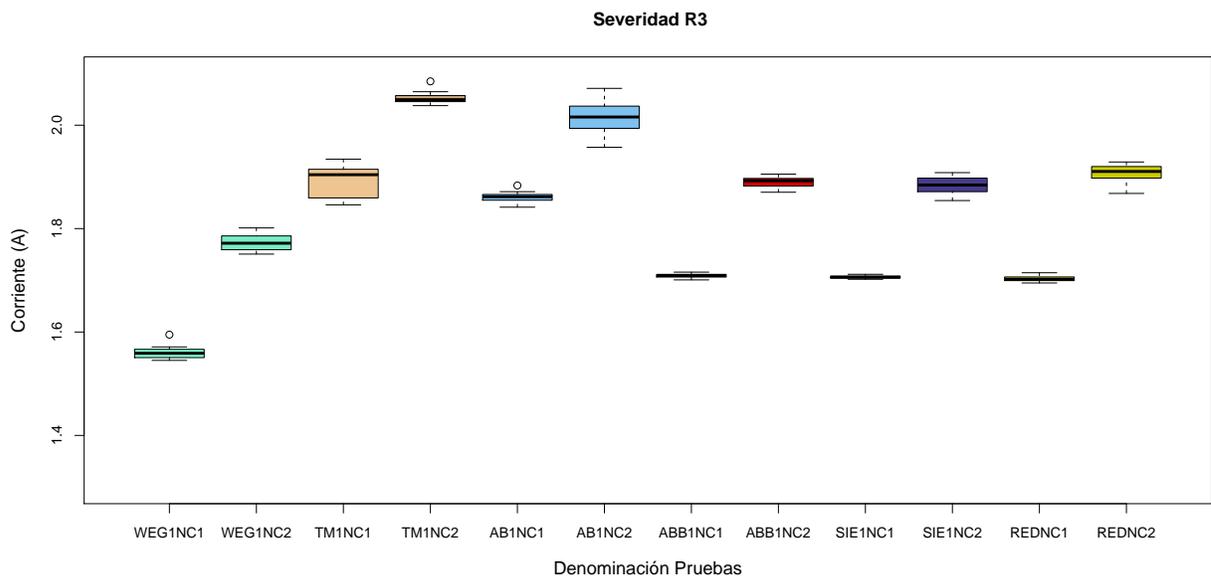


Figura B.5: Boxplots de las pruebas con los valores de corriente. Severidad R3.

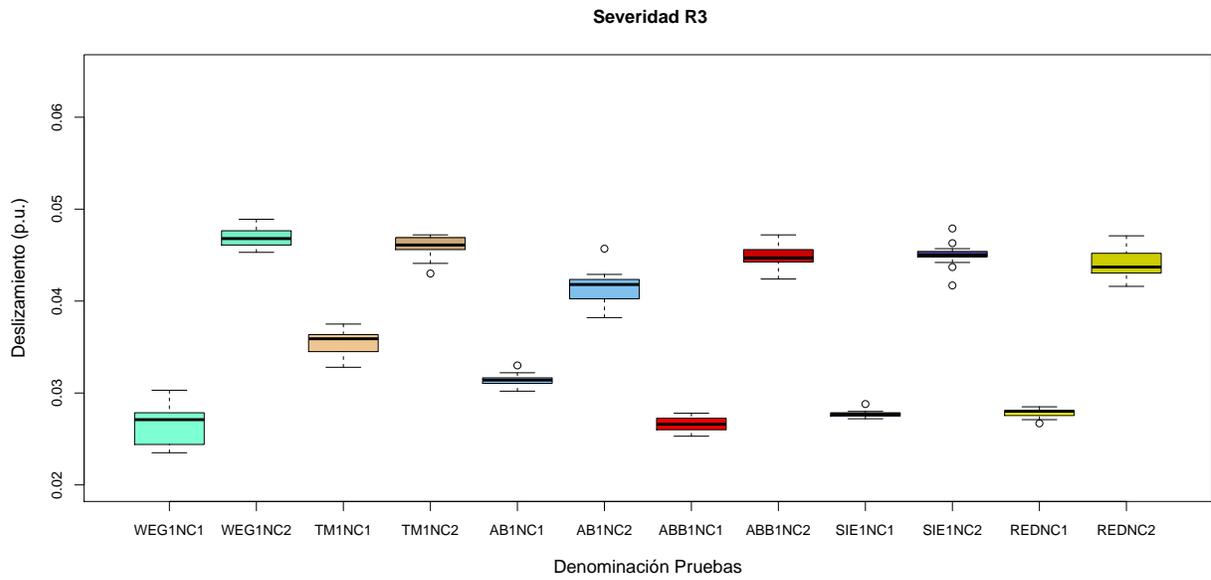


Figura B.6: Boxplots de las pruebas con los valores de deslizamiento. Severidad R3.

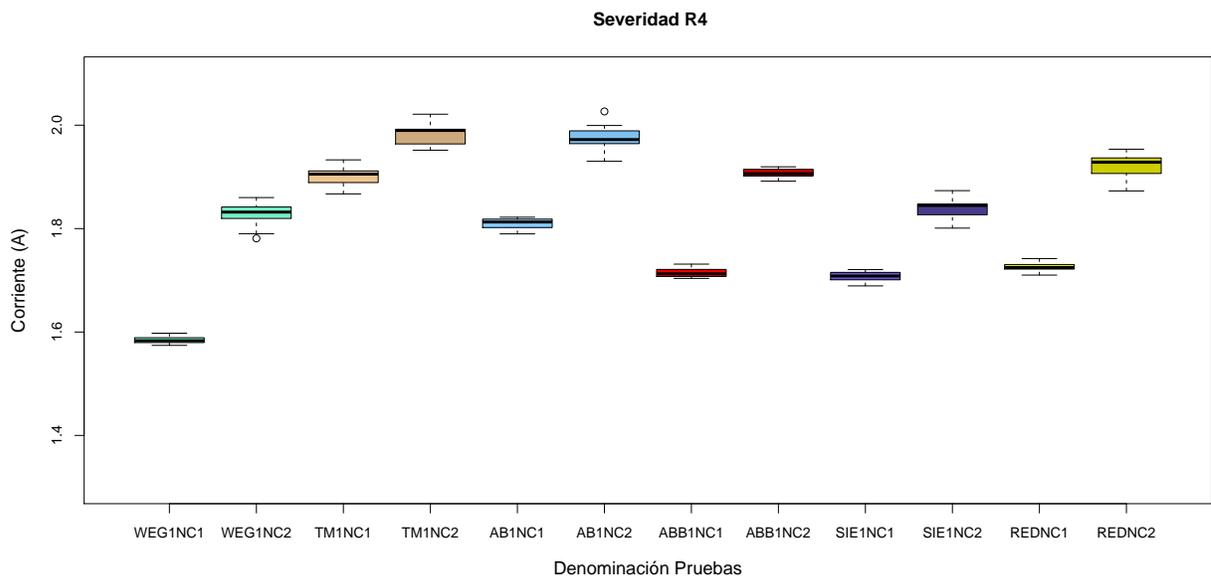


Figura B.7: Boxplots de las pruebas con los valores de corriente . Severidad R4.

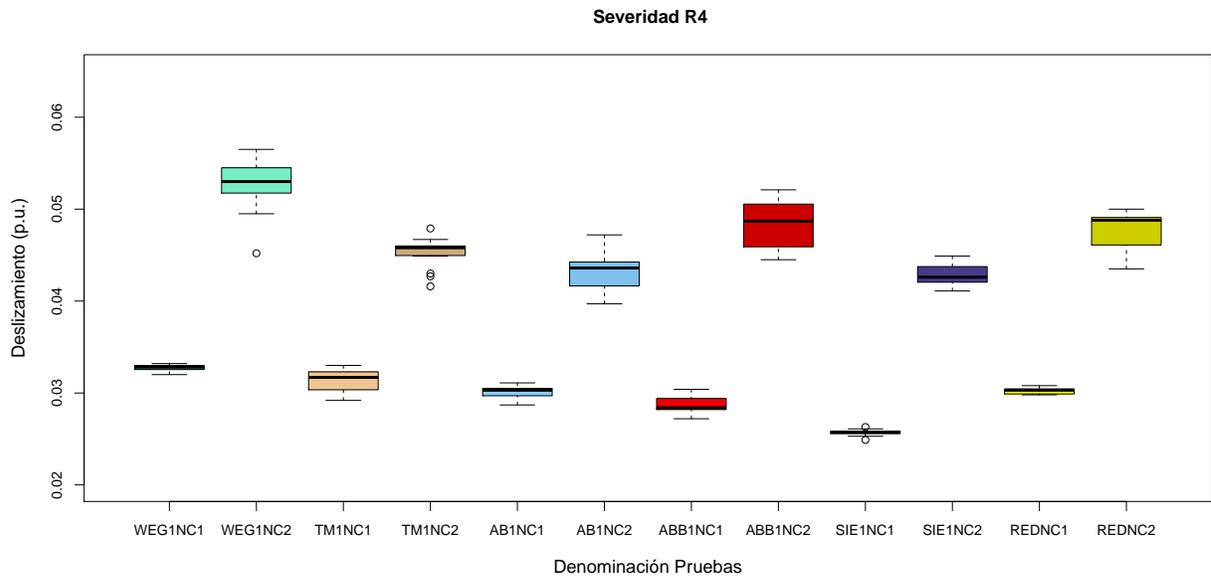


Figura B.8: Boxplots de las pruebas con los valores de deslizamiento. Severidad R4.

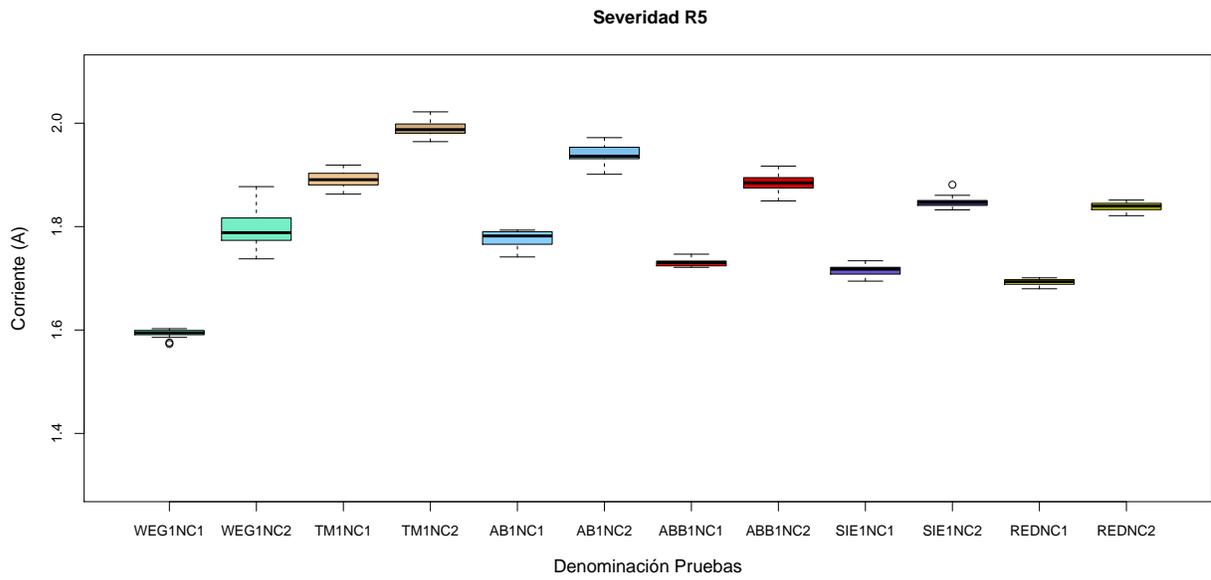


Figura B.9: Boxplots de las pruebas con los valores de corriente. Severidad R5.

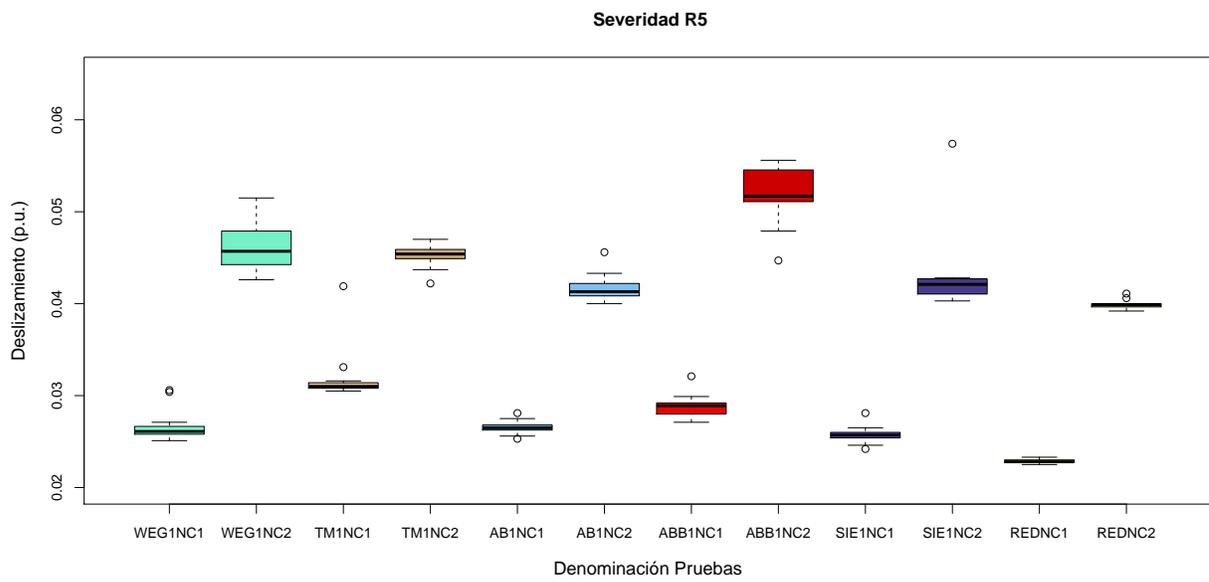


Figura B.10: Boxplots de las pruebas con los valores de deslizamiento. Severidad R5.

Apéndice C

Resultados adicionales.

C.1. Resumen estadístico de las variables empleadas.

A continuación (Tabla C.1) se presentan las estadísticas descriptivas de las variables calculadas con las señales obtenidas del desarrollo experimental.

Tipo de Alim.	Estado	NC	s [p.u.]	Veloc [rpm]	ALSH [dB]	ARSH [dB]
AB1 :150	R1:120	NC1:300	Min. :0.02260	Min. :1417	Min. :-104.90	Min. :-105.70
ABB1:150	R2:120	NC2:300	1st Qu.:0.02967	1st Qu.:1432	1st Qu.:-76.33	1st Qu.:-76.52
RED :150	R3:120		Median :0.03780	Median :1443	Median : -65.91	Median : -62.95
TM1 :150	R4:120		Mean :0.03744	Mean :1444	Mean : -66.66	Mean : -65.65
	R5:120		3rd Qu.:0.04540	3rd Qu.:1456	3rd Qu.:-56.70	3rd Qu.:-55.30
			Max. :0.05560	Max. :1466	Max. : -45.56	Max. : -44.58
f_{LSH} [Hz]	f_{RSH} [Hz]	Γ_5	Γ_7	Γ_{11}	Γ_{13}	m_1
Min. :44.40	Min. :52.30	Min. :1.340	Min. :0.3956	Min. :0.1781	Min. :0.1426	Min. :-7.160e-16
1st Qu.:45.50	1st Qu.:53.00	1st Qu.:2.133	1st Qu.:1.7314	1st Qu.:1.4422	1st Qu.:1.2811	1st Qu.:-6.800e-17
Median :46.20	Median :53.80	Median :2.326	Median :1.9763	Median :1.6005	Median :1.4473	Median : 6.195e-18
Mean :46.26	Mean :53.76	Mean :2.397	Mean :2.0348	Mean :1.6017	Mean :1.4781	Mean : 5.244e-18
3rd Qu.:47.00	3rd Qu.:54.50	3rd Qu.:2.631	3rd Qu.:2.3298	3rd Qu.:1.7437	3rd Qu.:1.6465	3rd Qu.: 7.778e-17
Max. :47.70	Max. :56.60	Max. :5.892	Max. :3.2990	Max. :2.4822	Max. :2.3828	Max. : 6.590e-16
m_2	m_3	m_4	c_1	c_2	c_3	c_4
Min. :-0.359000	Min. :11.94	Min. :-7.160e-16	Min. :2.812	Min. :-0.359389	Min. :-28.09	
1st Qu.:3.051	1st Qu.:0.183500	1st Qu.:14.17	1st Qu.:-6.800e-17	1st Qu.:3.051	1st Qu.:-0.183297	1st Qu.:-20.36
Median :3.523	Median :-0.082228	Median :18.82	Median : 6.195e-18	Median :3.523	Median :-0.082228	Median :-18.38
Mean :3.466	Mean :-0.090940	Mean :18.47	Mean : 5.244e-18	Mean :3.466	Mean :-0.090940	Mean :-18.02
3rd Qu.:3.704	3rd Qu.:0.009357	3rd Qu.:20.85	3rd Qu.: 7.778e-17	3rd Qu.:3.704	3rd Qu.:-0.009357	3rd Qu.:-13.92
Max. :4.376	Max. : 0.283000	Max. :29.36	Max. : 6.590e-16	Max. :4.376	Max. : 0.283127	Max. :-11.78
Skewness	Curtosis	\bar{x}_p	$ \bar{x} $	X_r	f_{aresta}	f_{forma}
Min. :1.500	Min. :1.513	Min. :2.417	Min. :1.388	Min. :1.427	Min. :1.108	Min. :1.677
1st Qu.:1.511	1st Qu.:1.572	1st Qu.:2.908	1st Qu.:1.438	1st Qu.:1.519	1st Qu.:1.112	1st Qu.:1.747
Median :1.517	Median :1.680	Median :3.161	Median :1.519	Median :1.704	Median :1.115	Median :1.877
Mean :1.518	Mean :1.664	Mean :3.142	Mean :1.510	Mean :1.689	Mean :1.117	Mean :1.859
3rd Qu.:1.525	3rd Qu.:1.725	3rd Qu.:3.382	3rd Qu.:1.563	3rd Qu.:1.816	3rd Qu.:1.121	3rd Qu.:1.925
Max. :1.540	Max. :1.860	Max. :4.033	Max. :1.681	Max. :2.089	Max. :1.137	Max. :2.092

Tabla C.1: Resumen estadístico de las variables usadas para el análisis equilibrado.

Bibliografía

- [1] R. Puche-Panadero, M. Pineda-Sanchez, M. Riera-Guasp, J. Roger-Folch, E. Hurtado-Perez, and J. Perez-Cruz, “Improved Resolution of the MCSA Method Via Hilbert Transform, Enabling the Diagnosis of Rotor Asymmetries at Very Low Slip,” *IEEE Trans. Energy Convers.*, vol. 24, pp. 52–59, mar 2009.
- [2] P. Gardel Sotomayor, *Aportaciones al mantenimiento predictivo de motores de inducción mediante una metodología de diagnóstico basada en el uso combinado de técnicas estadísticas y Redes Neuronales Artificiales*. PhD thesis, University of Valladolid, 2013.
- [3] M. Perez-Alonso, D. Morinigo-Sotelo, and O. Duque-Perez, “Railway traction electric motors. Characteristics and techniques of electric system maintenance — Los motores eléctricos de tracción ferroviaria. Características y técnicas de mantenimiento del sistema eléctrico,” *Dyna*, vol. 86, no. 4, 2011.
- [4] M. Nemec, K. Drobic, D. Nedeljkovic, R. Fiser, and V. Ambrozic, “Detection of Broken Bars in Induction Motor Through the Analysis of Supply Voltage Modulation,” *IEEE Trans. Ind. Electron.*, vol. 57, pp. 2879–2888, aug 2010.
- [5] S. B. Lee, D. Hyun, T.-j. Kang, C. Yang, S. Shin, H. Kim, S. Park, T.-S. Kong, and H.-D. Kim, “Identification of False Rotor Fault Indications Produced by Online MCSA for Medium-Voltage Induction Machines,” *IEEE Trans. Ind. Appl.*, vol. 52, pp. 729–739, jan 2016.
- [6] A. M. da Silva, Povinelli, and Demerdash, “Rotor Bar Fault Monitoring Method Based on Analysis of Air-Gap Torques of Induction Motors,” *IEEE Trans. Ind. Informat.*, vol. 9, pp. 2274–2283, nov 2013.

- [7] J. Hong, D. Hyun, S. Lee, and C. Kral, "Offline monitoring of airgap eccentricity for inverter-fed induction motors based on the differential inductance," *IEEE Trans. Ind. Appl.*, vol. 49, no. 6, 2013.
- [8] L. A. Garcia-Escudero, O. Duque-Perez, D. Morinigo-Sotelo, and M. Perez-Alonso, "Robust condition monitoring for early detection of broken rotor bars in induction motors," *Expert Syst. Appl.*, vol. 38, pp. 2653–2660, mar 2011.
- [9] M. Cabanas, M. Melero, G. Orcajo, and S. J. Cano, *Técnicas para el mantenimiento y diagnóstico de máquinas eléctricas rotativas*. Marcombo, 1998. Barcelona, Spain.
- [10] G. Kliman, R. Koegl, J. Stein, R. Endicott, and M. Madden, "Noninvasive detection of broken rotor bars in operating induction motors," *IEEE Trans. Energy Convers.*, vol. 3, no. 4, pp. 873–879, 1988.
- [11] B. Akin, S. Ozturk, H. Toliyat, and M. Rayner, "DSP-Based Sensorless Electric Motor Fault-Diagnosis Tools for Electric and Hybrid Electric Vehicle Powertrain Applications," *IEEE Trans. Veh. Technol.*, vol. 58, pp. 2679–2688, jul 2009.
- [12] A. Kusiak and A. Verma, "A Data-Mining Approach to Monitoring Wind Turbines," *IEEE Trans. Sustain. Energy*, vol. 3, pp. 150–157, jan 2012.
- [13] S. Yin, S. X. Ding, X. Xie, and H. Luo, "A review on basic data-driven approaches for industrial process monitoring," *IEEE Trans. Ind. Electron.*, vol. 61, no. 11, pp. 6418–6428, 2014.
- [14] V. Ghorbanian and J. Faiz, "A survey on time and frequency characteristics of induction motors with broken rotor bars in line-start and inverter-fed modes," *Mech. Syst. Signal Process.*, vol. 54, pp. 427–456, 2015.
- [15] J. Pons-Llinares, J. Antonino-Daviu, J. Roger-Folch, D. Morinigo-Sotelo, and O. Duque-Perez, "Mixed eccentricity diagnosis in Inverter-Fed Induction Motors via the Adaptive Slope Transform of transient stator currents," *Mech. Syst. Signal Process.*, vol. 48, pp. 423–435, oct 2014.
- [16] R. J. Romero-Troncoso, D. Morinigo-Sotelo, O. Duque-Perez, P. E. Gardel-Sotomayor, R. A. Osornio-Rios, and A. Garcia-Perez, "Early broken rotor bar detection techniques in VSD-fed induction motors at steady-state," in *2013 9th IEEE Int. Symp. Diagnostics Electr. Mach. Power Electron. Drives*, pp. 105–113, IEEE, aug 2013.

- [17] A. Naha, A. K. Samanta, A. Routray, and A. K. Deb, "A Method for Detecting Half-Broken Rotor Bar in Lightly Loaded Induction Motors Using Current," *IEEE Trans. Instrum. Meas.*, vol. 65, pp. 1614–1625, jul 2016.
- [18] A. Garcia-Perez, R. d. J. Romero-Troncoso, E. Cabal-Yepez, and R. A. Osornio-Rios, "The Application of High-Resolution Spectral Analysis for Identifying Multiple Combined Faults in Induction Motors," *IEEE Trans. Ind. Electron.*, vol. 58, pp. 2002–2010, may 2011.
- [19] V. Climente-Alarcon, J. A. Antonino-Daviu, E. G. Strangas, and M. Riera-Guasp, "Rotor-Bar Breakage Mechanism and Prognosis in an Induction Motor," *IEEE Trans. Ind. Electron.*, vol. 62, pp. 1814–1825, mar 2015.
- [20] F. Yang, M. S. Habibullah, T. Zhang, Z. Xu, P. Lim, and S. Nadarajan, "Health Index-Based Prognostics for Remaining Useful Life Predictions in Electrical Machines," *IEEE Trans. Ind. Electron.*, vol. 63, pp. 2633–2644, apr 2016.
- [21] B. Liang, S. Iwnicki, and Y. Zhao, "Application of power spectrum, cepstrum, higher order spectrum and neural network analyses for induction motor fault diagnosis," *Mech. Syst. Signal Process.*, vol. 39, pp. 342–360, aug 2013.
- [22] M. D. Prieto, G. Cirrincione, A. G. Espinosa, J. A. Ortega, and H. Henao, "Bearing fault detection by a novel condition-monitoring scheme based on statistical-time features and neural networks," *IEEE Trans. Ind. Electron.*, vol. 60, pp. 3398–3407, Aug 2013.
- [23] M. R. Mehrjou, N. Mariun, M. Hamiruce Marhaban, and N. Misron, "Rotor fault condition monitoring techniques for squirrel-cage induction machine - A review," *Mech. Syst. Signal Process.*, vol. 25, no. 8, pp. 2827–2848, 2011.
- [24] M. G. *et al.*, "Report of Large Motor Reliability Survey of Industrial and Commercial Installations, Part I," *IEEE Trans. Ind. Appl.*, vol. 21, no. 4, pp. 853–864, 1985.
- [25] P. F. Albrecht, J. C. Appiarius, R. M. McCoy, E. L. Owen, and D. K. Sharma, "Assessment of the Reliability of Motors in Utility Applications - Updated," *IEEE Power Eng. Rev.*, vol. PER-6, pp. 31–32, mar 1986.
- [26] O. Thorsen and M. Dalva, "Failure identification and analysis for high-voltage induction motors in the petrochemical industry," *IEEE Trans. Ind. Appl.*, vol. 35, no. 4, pp. 810–818, 1999.

- [27] E. Fournier, *Protocole de diagnostic des entraînements asynchrones par références: application à la détection des déséquilibres mécaniques et des défauts de courroie*. PhD thesis, Institut National Polytechnique de Toulouse (INP Toulouse), 2015.
- [28] E. Gaucheron, “Cuaderno Técnico Schneider no. 207,” tech. rep., Schneider Electric, 03 2005.
- [29] H. A. Toliyat, S. Nandi, S. Choi, and H. Meshgin-Kelk, *Electric Machines: Modeling, Condition Monitoring, and Fault Diagnosis*. CRC Press, 2016. New York, USA.
- [30] M. Drif and A. J. M. Cardoso, “Stator Fault Diagnostics in Squirrel Cage Three-Phase Induction Motor Drives Using the Instantaneous Active and Reactive Power Signature Analyses,” *IEEE Trans. Ind. Informat.*, vol. 10, pp. 1348–1360, may 2014.
- [31] L. A. Dissado and J. C. Fothergill, *Electrical Degradation and Breakdown in Polymers*. Ed., IET Materials and Devices Series 9., 1992. Stevenage, United Kingdom.
- [32] D. Morinigo-Sotelo, L. Garcia-Escudero, O. Duque-Perez, and M. Perez-Alonso, “Practical Aspects of Mixed-Eccentricity Detection in PWM Voltage-Source-Inverter-Fed Induction Motors,” *IEEE Trans. Ind. Electron.*, vol. 57, pp. 252–262, jan 2010.
- [33] S. Nandi, R. Bharadwaj, and H. Toliyat, “Performance analysis of a three-phase induction motor under mixed eccentricity condition,” *IEEE Trans. Energy Convers.*, vol. 17, pp. 392–399, sep 2002.
- [34] J. M. Cortés López, *Técnicas optimizadas de análisis de señal en dominio tiempo-frecuencia para el diagnóstico de máquinas de inducción en régimen transitorio*. PhD thesis, Universitat Politècnica de València, 2015.
- [35] V. Climente Alarcón, *Apotación al Mantenimiento Predictivo de Motores de Inducción Mediante Modernas Técnicas de Análisis de la Señal*. PhD thesis, Universitat Politècnica de València, 2012.
- [36] R. Schoen, T. Habetler, F. Kamran, and R. Bartfield, “Motor bearing damage detection using stator current monitoring,” *IEEE Trans. Ind. Appl.*, vol. 31, no. 6, pp. 1274–1279, 1995.
- [37] M. E. H. Benbouzid, “A review of induction motors signature analysis as a medium for faults detection,” *IEEE Trans. Ind. Electron.*, vol. 47, no. 5, pp. 984–993, 2000.

- [38] M. Cabanas, J. Ruiz Gonzalez, J. Sampayo, M. Melero, C. Rojas, F. Pedrayes, A. Arguelles, and J. Vina, "Analysis of the fatigue causes on the rotor bars of squirrel cage asynchronous motors: experimental analysis and modelling of medium voltage motors," in *4th IEEE Int. Symp. Diagnostics Electr. Mach. Power Electron. Drives, 2003. SDEMPED 2003.*, pp. 247–252, IEEE.
- [39] J. Kim, S. Shin, S. B. Lee, K. N. Gyftakis, M. Drif, and A. J. M. Cardoso, "Power Spectrum-Based Detection of Induction Motor Rotor Faults for Immunity to False Alarms," *IEEE Trans. Energy Convers.*, vol. 30, pp. 1123–1132, sep 2015.
- [40] H. Henao, H. Razik, and G.-A. Capolino, "Analytical Approach of the Stator Current Frequency Harmonics Computation for Detection of Induction Machine Rotor Faults," *IEEE Trans. Ind. Appl.*, vol. 41, pp. 801–807, may 2005.
- [41] F. Filippetti, G. Franceschini, C. Tassoni, and P. Vas, "AI techniques in induction machines diagnosis including the speed ripple effect," *IEEE Trans. Ind. Appl.*, vol. 34, no. 1, pp. 98–108, 1998.
- [42] G. Didier, E. Ternisien, O. Caspary, and H. Razik, "Fault detection of broken rotor bars in induction motor using a global fault index," *IEEE Trans. Ind. Appl.*, vol. 42, pp. 79–88, jan 2006.
- [43] M. O. Mustafa, D. Varagnolo, G. Nikolakopoulos, and T. Gustafsson, "Detecting broken rotor bars in induction motors with model-based support vector classifiers," *Control Eng. Pract.*, vol. 52, pp. 15–23, jul 2016.
- [44] A. Bellini, F. Filippetti, G. Franceschini, C. Tassoni, and G. Kliman, "Quantitative evaluation of induction motor broken bars by means of electrical signature analysis," *IEEE Trans. Ind. Appl.*, vol. 37, no. 5, pp. 1248–1255, 2001.
- [45] P. Pennacchi, N. Bachschmid, A. Vania, G. A. Zanetta, and L. Gregori, "Use of modal representation for the supporting structure in model-based fault identification of large rotating machinery: part 1"theoretical remarks," *Mech. Syst. Signal Process.*, vol. 20, pp. 662–681, apr 2006.
- [46] H. Penrose, "Estimating motor life using motor circuit analysis predictive measurements. Part II," in *Conf. Rec. 2004 IEEE Int. Symp. Electr. Insul.*, pp. 15–17, IEEE.

- [47] C. J. Verucchi and G. G. Acosta, "Fault Detection and Diagnosis Techniques in Induction Electrical Machines," *IEEE Lat. Am. Trans.*, vol. 5, pp. 41–49, mar 2007.
- [48] S. Sheng, L. Zhang, and R. Gao, "A Systematic Sensor-Placement Strategy for Enhanced Defect Detection in Rolling Bearings," *IEEE Sens. J.*, vol. 6, pp. 1346–1354, oct 2006.
- [49] A. Prudhom, J. Antonino-Daviu, H. Razik, and V. Climente-Alarcon, "Time-frequency vibration analysis for the detection of motor damages caused by bearing currents," *Mech. Syst. Signal Process.*, vol. 84, pp. 747–762, feb 2017.
- [50] D. Camarena-Martinez, M. Valtierra-Rodriguez, J. P. Amezquita-Sanchez, D. Granados-Lieberman, R. J. Romero-Troncoso, and A. Garcia-Perez, "Shannon Entropy and K-Means Method for Automatic Diagnosis of Broken Rotor Bars in Induction Motors Using Vibration Signals," *Shock and Vibration*, vol. 2016, pp. 1–10, 2016.
- [51] P. A. Delgado-Arredondo, A. Garcia-Perez, D. Morinigo-Sotelo, R. A. Osornio-Rios, J. G. Avina-Cervantes, H. Rostro-Gonzalez, and R. d. J. Romero-Troncoso, "Comparative Study of Time-Frequency Decomposition Techniques for Fault Detection in Induction Motors Using Vibration Analysis during Startup Transient," *Shock and Vibration*, vol. 2015, pp. 1–14, 2015.
- [52] K. Bacha, H. Henao, M. Gossa, and G.-A. Capolino, "Induction machine fault detection using stray flux EMF measurement and neural network-based decision," *Electr. Power Syst. Res.*, vol. 78, pp. 1247–1255, jul 2008.
- [53] L. Frosini, C. Harlisca, and L. Szabo, "Induction Machine Bearing Fault Detection by Means of Statistical Processing of the Stray Flux Measurement," *IEEE Trans. Ind. Electron.*, vol. 62, pp. 1846–1854, mar 2015.
- [54] V. Thomas, K. Vasudevan, and V. Kumar, "Online cage rotor fault detection using air-gap torque spectra," *IEEE Trans. Energy Convers.*, vol. 18, pp. 265–270, jun 2003.
- [55] A. Trzynadlowski and E. Ritchie, "Comparative investigation of diagnostic media for induction motors: a case of rotor cage faults," *IEEE Trans. Ind. Electron.*, vol. 47, no. 5, pp. 1092–1099, 2000.

- [56] C. Kral, T. Habetler, and R. Harley, "Detection of Mechanical Imbalances of Induction Machines Without Spectral Analysis of Time-Domain Signals," *IEEE Trans. Ind. Appl.*, vol. 40, pp. 1101–1106, jul 2004.
- [57] Z. Liu, X. Yin, Z. Zhang, D. Chen, and W. Chen, "Online Rotor Mixed Fault Diagnosis Way Based on Spectrum Analysis of Instantaneous Power in Squirrel Cage Induction Motors," *IEEE Trans. Energy Convers.*, vol. 19, pp. 485–490, sep 2004.
- [58] H. Henao, C. Martis, and G.-A. Capolino, "An Equivalent Internal Circuit of the Induction Machine for Advanced Spectral Analysis," *IEEE Trans. Ind. Appl.*, vol. 40, pp. 726–734, may 2004.
- [59] J. Milimonfared, H. Kelk, S. Nandi, A. Minassians, and H. Toliyat, "A novel approach for broken-rotor-bar detection in cage induction motors," *IEEE Trans. Ind. Appl.*, vol. 35, no. 5, pp. 1000–1006, 1999.
- [60] A. Glowacz, "Diagnostics of rotor damages of three-phase induction motors using acoustic signals and smofs-20-expanded," *Archives of Acoustics*, vol. 41, no. 3, pp. 507–515, 2016.
- [61] P. A. Delgado-Arredondo, D. Morinigo-Sotelo, R. A. Osornio-Rios, J. G. Avina-Cervantes, H. Rostro-Gonzalez, and R. d. J. Romero-Troncoso, "Methodology for fault detection in induction motors via sound and vibration signals," *Mech. Syst. Signal Process.*, vol. 83, pp. 568–589, jan 2017.
- [62] F. Salazar-Villanueva and O. G. Ibarra-Manzano, "Spectral analysis for identifying faults in induction motors by means of sound," in *CONIELECOMP 2013, 23rd Int. Conf. Electron. Commun. Comput.*, pp. 149–153, IEEE, mar 2013.
- [63] D. Lopez-Perez and J. Antonino-Daviu, "Application of infrared thermography to failure detection in industrial induction motors: case stories," *IEEE Trans. Ind. Appl.*, pp. 1901–1908, 2017.
- [64] A. Glowacz and Z. Glowacz, "Diagnosis of the three-phase induction motor using thermal imaging," *Infrared Phys. Technol.*, vol. 81, pp. 7–16, mar 2017.
- [65] M. J. Picazo-Rodenas, J. Antonino-Daviu, V. Climente-Alarcon, R. Royo-Pastor, and A. Mota-Villar, "Combination of Noninvasive Approaches for General Assessment of Induction Motors," *IEEE Trans. Ind. Appl.*, vol. 51, no. 3, pp. 2172–2180, 2015.

- [66] C. Kral, T. Habetler, R. Harley, F. Pirker, G. Pascoli, H. Oberguggenberger, and C. Fenz, "A comparison of rotor fault detection techniques with respect to the assessment of fault severity," in *4th IEEE Int. Symp. Diagnostics Electr. Mach. Power Electron. Drives, 2003. SDEMPED 2003.*, pp. 265–270, IEEE.
- [67] M. Haji and H. Toliyat, "Pattern recognition-a technique for induction machines rotor broken bar detection," *IEEE Trans. Energy Convers.*, vol. 16, no. 4, pp. 312–317, 2001.
- [68] W. Thomson and M. Fenger, "Current signature analysis to detect induction motor faults," *IEEE Ind. Appl. Mag.*, vol. 7, no. 4, pp. 26–34, 2001.
- [69] C. Bruzzese, "Analysis and Application of Particular Current Signatures (Symptoms) for Cage Monitoring in Nonsinusoidally Fed Motors With High Rejection to Drive Load, Inertia, and Frequency Variations," *IEEE Trans. Ind. Electron.*, vol. 55, pp. 4137–4155, dec 2008.
- [70] S. Cruz and A. Cardoso, "Stator winding fault diagnosis in three-phase synchronous and asynchronous motors, by the extended Park's vector approach," *IEEE Trans. Ind. Appl.*, vol. 37, no. 5, pp. 1227–1233, 2001.
- [71] R. Puche Panadero, *Nuevos métodos de diagnosis de excentricidad y otras asimetrías rotóricas en máquinas de inducción a través del análisis de la corriente estática*, year = 2008. PhD thesis, Universitat Politècnica de València.
- [72] J. Zarei, "Induction motors bearing fault detection using pattern recognition techniques," *Expert Syst. Appl.*, vol. 39, pp. 68–73, jan 2012.
- [73] M. Mortada, S. Yacout, and A. Lakis, "Diagnosis of rotor bearings using logical analysis of data," *J. Qual. Maint. Eng.*, vol. 17, pp. 371–397, oct 2011.
- [74] V. N. Ghate and S. V. Dudul, "Optimal MLP neural network classifier for fault detection of three phase induction motor," *Expert Syst. Appl.*, vol. 37, pp. 3468–3481, apr 2010.
- [75] J. Mendel, "Tutorial on higher-order statistics (spectra) in signal processing and system theory: theoretical results and some applications," *Proc. IEEE*, vol. 79, pp. 278–305, mar 1991.

- [76] B. Ayhan, H. Trussell, M.-Y. Chow, and M.-H. Song, "On the use of a lower sampling rate for broken rotor bar detection with DTFT and AR-based spectrum methods," *IEEE Trans. Ind. Electron.*, vol. 55, no. 3, pp. 1421–1434, 2008.
- [77] M. Benbouzid and G. Kliman, "What stator current processing-based technique to use for induction motor rotor faults diagnosis?," *IEEE Trans. Energy Convers.*, vol. 18, pp. 238–244, jun 2003.
- [78] R. Romero-Troncoso, "Multirate Signal Processing to Improve FFT-based Analysis for Detecting Faults in Induction Motors," *IEEE Trans. Ind. Informat.*, vol. Vol. 13, no. 3, no. 99, pp. 1291 – 1300, 2016.
- [79] L. Saidi, F. Fnaiech, H. Henao, G.-A. Capolino, and G. Cirrincione, "Diagnosis of broken-bars fault in induction machines using higher order spectral analysis," *ISA Trans.*, vol. 52, no. 1, pp. 140–148, 2013.
- [80] F. Harris, "On the use of windows for harmonic analysis with the discrete Fourier transform," *Proc. IEEE*, vol. 66, no. 1, pp. 51–83, 1978.
- [81] A. Testa, D. Gallo, and R. Langella, "On the Processing of Harmonics and Interharmonics: Using Hanning Window in Standard Framework," *IEEE Trans. Power Deliv.*, vol. 19, pp. 28–34, jan 2004.
- [82] C. Shannon, "Communication in the Presence of Noise," *Proc. IRE*, vol. 37, pp. 10–21, jan 1949.
- [83] I. Aydin, M. Karakose, and E. Akin, "A new method for early fault detection and diagnosis of broken rotor bars," *Energy Convers. Manag.*, vol. 52, pp. 1790–1799, apr 2011.
- [84] A. Unsal and A. Kabul, "Detection of the broken rotor bars of squirrel-cage induction motors based on normalized least mean square filter and Hilbert envelope analysis," *Electr. Eng.*, vol. 98, pp. 245–256, sep 2016.
- [85] M. Feldman, "Hilbert transform in vibration analysis," *Mech. Syst. Signal Process.*, vol. 25, pp. 735–802, apr 2011.
- [86] L. Marple, "Computing the discrete-time analytic signal via fft," *IEEE Trans. Signal Process.*, vol. 47, no. 9, pp. 2600–2603, 1999.

- [87] Y.-H. Kim, Y.-W. Youn, D.-H. Hwang, J.-H. Sun, and D.-S. Kang, “High-Resolution Parameter Estimation Method to Identify Broken Rotor Bar Faults in Induction Motors,” *IEEE Trans. Ind. Electron.*, vol. 60, pp. 4103–4117, sep 2013.
- [88] A. Sapena-Bano, J. Burriel-Valencia, M. Pineda-Sanchez, R. Puche-Panadero, and M. Riera-Guasp, “The Harmonic Order Tracking Analysis Method for the Fault Diagnosis in Induction Motors Under Time-Varying Conditions,” *IEEE Trans. Energy Convers.*, vol. 32, pp. 244–256, mar 2017.
- [89] A. Sapena-Bano, M. Pineda-Sanchez, R. Puche-Panadero, J. Perez-Cruz, J. Roger-Folch, M. Riera-Guasp, and J. Martinez-Roman, “Harmonic Order Tracking Analysis: A Novel Method for Fault Diagnosis in Induction Machines,” *IEEE Trans. Energy Convers.*, vol. 30, pp. 833–841, sep 2015.
- [90] V. Climente-Alarcon, J. A. Antonino-Daviu, F. Vedreno-Santos, and R. Puche-Panadero, “Vibration Transient Detection of Broken Rotor Bars by PSH Sidebands,” *IEEE Trans. Ind. Appl.*, vol. 49, pp. 2576–2582, nov 2013.
- [91] J. Pons-Llinares, J. Antonino-Daviu, J. Roger-Folch, D. Moríñigo-Sotelo, and O. Duque-Pérez, “Eccentricity diagnosis in inverter - Fed induction motors via the analytic wavelet transform of transient currents,” in *19th Int. Conf. Electr. Mach. ICEM 2010*, 2010.
- [92] R. Romero-Troncoso, A. Garcia-Perez, D. Morinigo-Sotelo, O. Duque-Perez, R. Osornio-Rios, and M. Ibarra-Manzano, “Rotor unbalance and broken rotor bar detection in inverter-fed induction motors at start-up and steady-state regimes by high-resolution spectral analysis,” *Electr. Power Syst. Res.*, vol. 133, pp. 142–148, apr 2016.
- [93] T. A. Garcia-Calva, D. Morinigo-Sotelo, and R. de Jesus Romero-Troncoso, “Non-Uniform Time Resampling for Diagnosing Broken Rotor Bars in Inverter-Fed Induction Motors,” *IEEE Trans. Ind. Electron.*, vol. 64, pp. 2306–2315, mar 2017.
- [94] A. Haghani Abandan Sari, *Data-Driven Design of Fault Diagnosis Systems*. Wiesbaden: Springer Fachmedien Wiesbaden, 2014. Rostock, Germany.
- [95] A. Bellini, F. Filippetti, C. Tassoni, and G.-A. Capolino, “Advances in Diagnostic Techniques for Induction Machines,” *IEEE Trans. Ind. Electron.*, vol. 55, pp. 4109–4126, dec 2008.

-
- [96] C. M. Bishop, *Pattern Recognition and Machine Learning (Information Science and Statistics)*. Springer-Verlag New York, Inc., 2006. Secaucus, USA.
- [97] S. Kolla and L. Varatharasa, “Identifying three-phase induction motor faults using artificial neural networks,” *ISA Trans.*, vol. 39, pp. 433–439, sep 2000.
- [98] J. Zarei, M. Tajeddini, and H. Karimi, “Vibration analysis for bearing fault detection and classification using an intelligent filter,” *Mechatronics*, vol. 24, no. 2, pp. 151–157, 2014.
- [99] H. Su and K. T. Chong, “Induction Machine Condition Monitoring Using Neural Network Modeling,” *IEEE Trans. Ind. Electron.*, vol. 54, pp. 241–249, feb 2007.
- [100] F. Filippetti, G. Franceschini, C. Tassoni, and P. Vas, “Recent developments of induction motor drives fault diagnosis using AI techniques,” *IEEE Trans. Ind. Electron.*, vol. 47, no. 5, pp. 994–1004, 2000.
- [101] G. Salles, F. Filippetti, C. Tassoni, G. Crellet, and G. Franceschini, “Monitoring of induction motor load by neural network techniques,” *IEEE Trans. Power Electron.*, vol. 15, pp. 762–768, jul 2000.
- [102] O. Ondel, E. Boutleux, and G. Clerc, “A method to detect broken bars in induction machine using pattern recognition techniques,” *IEEE Trans. Ind. Appl.*, vol. 42, pp. 916–923, jul 2006.
- [103] P. V. J. Rodríguez, M. Negrea, and A. Arkkio, “A simplified scheme for induction motor condition monitoring,” *Mech. Syst. Signal Process.*, vol. 22, pp. 1216–1236, jul 2008.
- [104] A. Verma, S. Sarangi, and M. Kolekar, “Stator winding fault prediction of induction motors using multiscale entropy and grey fuzzy optimization methods,” *Comput. Electr. Eng.*, vol. 40, pp. 2246–2258, oct 2014.
- [105] W. Godoy, I. da Silva, A. Goedel, R. Palácios, and T. Lopes, “Application of intelligent tools to detect and classify broken rotor bars in three-phase induction motors fed by an inverter,” *IET Electr. Power Appl.*, vol. 10, no. 5, pp. 430 – 439, 2016.
- [106] M. Seera, C. P. Lim, S. Nahavandi, and C. K. Loo, “Condition monitoring of induction motors: A review and an application of an ensemble of hybrid intelligent models,” *Expert Syst. Appl.*, vol. 41, pp. 4891–4903, aug 2014.

- [107] V. T. Tran, B.-S. Yang, M.-S. Oh, and A. C. C. Tan, “Fault diagnosis of induction motor based on decision trees and adaptive neuro-fuzzy inference,” *Expert Syst. Appl.*, vol. 36, pp. 1840–1849, mar 2009.
- [108] M. Diaz, P. Henriquez, M. A. Ferrer, G. Pirlo, J. B. Alonso, C. Carmona-Duarte, and D. Impedovo, “Stability-based system for bearing fault early detection,” *Expert Syst. Appl.*, vol. 79, pp. 65–75, aug 2017.
- [109] A. Ordaz-Moreno, R. de Jesus Romero-Troncoso, J. Vite-Frias, J. Rivera-Gillen, and A. Garcia-Perez, “Automatic Online Diagnosis Algorithm for Broken-Bar Detection on Induction Motors Based on Discrete Wavelet Transform for FPGA Implementation,” *IEEE Trans. Ind. Electron.*, vol. 55, pp. 2193–2202, may 2008.
- [110] G. Niu, A. Widodo, J.-D. Son, B.-S. Yang, D.-H. Hwang, and D.-S. Kang, “Decision-level fusion based on wavelet decomposition for induction motor fault diagnosis using transient current signal,” *Expert Syst. Appl.*, vol. 35, pp. 918–928, oct 2008.
- [111] Z. Xu, J. Xuan, T. Shi, B. Wu, and Y. Hu, “A novel fault diagnosis method of bearing based on improved fuzzy ARTMAP and modified distance discriminant technique,” *Expert Syst. Appl.*, vol. 36, pp. 11801–11807, nov 2009.
- [112] Y. Lei, Z. He, and Y. Zi, “Application of an intelligent classification method to mechanical fault diagnosis,” *Expert Syst. Appl.*, vol. 36, pp. 9941–9948, aug 2009.
- [113] V. N. Vapnik, *The Nature of Statistical Learning Theory*. New York, NY, USA: Springer-Verlag New York, Inc., 1995. New York, USA.
- [114] T. Hastie, R. Tibshirani, and J. Friedman, *The Elements of Statistical Learning*. Springer Series in Statistics, New York, NY: Springer New York, 2009. New York, USA.
- [115] J. C. Platt, “Advances in kernel methods,” ch. Fast Training of Support Vector Machines Using Sequential Minimal Optimization, pp. 185–208, Cambridge, MA, USA: MIT Press, 1999. Cambridge, USA.
- [116] L. M. R. Baccarini, V. V. Rocha e Silva, B. R. de Menezes, and W. M. Caminhas, “SVM practical industrial application for mechanical faults diagnostic,” *Expert Syst. Appl.*, vol. 38, pp. 6980–6984, jun 2011.

- [117] A. Widodo and B.-S. Yang, “Wavelet support vector machine for induction machine fault diagnosis based on transient current signal,” *Expert Syst. Appl.*, vol. 35, no. 1, pp. 307–316, 2008.
- [118] A. Widodo, B.-S. Yang, D.-S. Gu, and B.-K. Choi, “Intelligent fault diagnosis system of induction motor based on transient current signal,” *Mechatronics*, vol. 19, pp. 680–689, aug 2009.
- [119] M. Fernandez-Temprano, P. E. Gardel-Sotomayor, O. Duque-Perez, and D. Morinigo-Sotelo, “Broken bar condition monitoring of an induction motor under different supplies using a linear discriminant analysis,” in *2013 9th IEEE Int. Symp. Diagnostics Electr. Mach. Power Electron. Drives*, pp. 162–168, IEEE, aug 2013.
- [120] O. Duque-Perez, L.-A. Garcia-Escudero, D. Morinigo-Sotelo, P.-E. Gardel, and M. Perez-Alonso, “Analysis of fault signatures for the diagnosis of induction motors fed by voltage source inverters using ANOVA and additive models,” *Electr. Power Syst. Res.*, vol. 121, pp. 1–13, apr 2015.
- [121] Z. Pan, Y. Wang, and W. Ku, “A new k-harmonic nearest neighbor classifier based on the multi-local means,” *Expert Syst. Appl.*, vol. 67, pp. 115–125, 2017.
- [122] R. Cunha Palacios, I. Da Silva, A. Goedel, and W. Godoy, “A comprehensive evaluation of intelligent classifiers for fault identification in three-phase induction motors,” *Electr. Power Syst. Res.*, vol. 127, pp. 249–258, 2015.
- [123] A. Bacchus, M. Biet, L. Macaire, Y. L. Menach, and A. Tounzi, “Comparison of supervised classification algorithms combined with feature extraction and selection: Application to a turbo-generator rotor fault detection,” in *2013 9th IEEE Int. Symp. Diagnostics Electr. Mach. Power Electron. Drives*, pp. 558–565, IEEE, aug 2013.
- [124] J.-D. Son, G. Niu, B.-S. Yang, D.-H. Hwang, and D.-S. Kang, “Development of smart sensors system for machine fault diagnosis,” *Expert Syst. Appl.*, vol. 36, pp. 11981–11991, nov 2009.
- [125] M. Seera, C. P. Lim, and C. K. Loo, “Motor fault detection and diagnosis using a hybrid FMM-CART model with online learning,” *J. Intell. Manuf.*, vol. 27, pp. 1273–1285, dec 2016.

- [126] R. K. Patel and V. Giri, "Feature selection and classification of mechanical fault of an induction motor using random forest classifier," *Perspect. Sci.*, vol. 8, pp. 334–337, sep 2016.
- [127] B.-S. Yang, X. Di, and T. Han, "Random forests classifier for machine fault diagnosis," *J. Mech. Sci. Technol.*, vol. 22, pp. 1716–1725, sep 2008.
- [128] V. López, A. Fernández, S. García, V. Palade, and F. Herrera, "An insight into classification with imbalanced data: Empirical results and current trends on using data intrinsic characteristics," *Inf. Sci. (Ny)*, vol. 250, pp. 113–141, nov 2013.
- [129] N. Japkowicz and M. Shah, *Evaluating Learning Algorithms: A Classification Perspective*. New York, NY, USA: Cambridge University Press, 2011.
- [130] G. Santafe, I. n. Inza, and J. A. Lozano, "Dealing with the evaluation of supervised classification algorithms," *Artif. Intell. Rev.*, vol. 44, pp. 467–508, Dec. 2015.
- [131] I. Boldea and S. A. Nasar, *The induction machine handbook*. CRC press, 2010. Boca Raton, USA.
- [132] T. H. dos Santos, A. Goedel, S. A. O. da Silva, and M. Suetake, "Scalar control of an induction motor using a neural sensorless technique," *Electr. Power Syst. Res.*, vol. 108, pp. 322–330, 2014.
- [133] B. Wu and M. Narimani, *High-power converters and AC drives*. John Wiley & Sons, 2016.
- [134] D. G. Holmes and T. A. Lipo, *Pulse width modulation for power converters: principles and practice*, vol. 18. John Wiley & Sons, 2003. Washington DC, USA.
- [135] S. R. H. Amrei and D. G. Xu, "A new study on harmonics and interharmonics reduction with frequency selective closed-loop control in vsi inverters," in *Vehicle Power and Propulsion Conference, 2008. VPPC'08. IEEE*, pp. 1–6, IEEE, 2008.
- [136] Y. Plotkin, M. Stiebler, and D. Hofmeyer, "Sixth torque harmonic in pwm inverter-fed induction drives and its compensation," *IEEE Trans. Ind. Appl.*, vol. 41, no. 4, pp. 1067–1074, 2005.
- [137] J. Song-Manguelle, J.-M. Nyobe-Yome, and G. Ekemb, "Pulsating torques in pwm multi-megawatt drives for torsional analysis of large shafts," *IEEE Trans. Ind. Appl.*, vol. 46, no. 1, pp. 130–138, 2010.

- [138] J. Song-Manguelle, C. Sihler, and S. Schramm, "A general approach of damping torsional resonance modes in multimegawatt applications," *IEEE Trans. Ind. Appl.*, vol. 47, no. 3, pp. 1390–1399, 2011.
- [139] S. B. Chaudhury and S. Gupta, "Online identification of ac motor misalignment using current signature analysis and modified k-mean clustering technique," in *Industrial Technology, 2006. ICIT 2006. IEEE International Conference on*, pp. 2331–2336, IEEE, 2006.
- [140] Ó. Duque and M. Pérez, "Motores de inducción: Técnicas de mantenimiento predictivo," *Abecedario Sept*, 2005. Badajoz, Spain.
- [141] R. Wieser, C. Kral, F. Pirker, and M. Schagginger, "On-line rotor cage monitoring of inverter-fed induction machines by means of an improved method," *IEEE Trans. Power Electron.*, vol. 14, no. 5, pp. 858–865, 1999.
- [142] B. Akin, U. Orguner, H. A. Toliyat, and M. Rayner, "Low Order PWM Inverter Harmonics Contributions to the Inverter-Fed Induction Machine Fault Diagnosis," *IEEE Trans. Ind. Electron.*, vol. 55, no. 2, pp. 610–619, 2008.
- [143] F. Briz, M. W. Degner, P. Garcia, and A. B. Diez, "High-frequency carrier-signal voltage selection for stator winding fault diagnosis in inverter-fed ac machines," *IEEE Trans. Ind. Electron.*, vol. 55, no. 12, pp. 4181–4190, 2008.
- [144] A. Bellini, F. Filippetti, G. Franceschini, and C. Tassoni, "Closed-loop control impact on the diagnosis of induction motors faults," *IEEE Trans. Ind. Appl.*, vol. 36, no. 5, pp. 1318–1329, 2000.
- [145] C. C. Cunha, B. J. Cardoso Filho, and R. O. Lvra, "Detection of rotor faults in torque controlled induction motor drives," in *Power Electronics and Applications, 2007 European Conference on*, pp. 1–10, IEEE, 2007.
- [146] B. Akin, U. Orguner, H. A. Toliyat, and M. Rayner, "Phase-sensitive detection of motor fault signatures in the presence of noise," *IEEE Trans. Ind. Electron.*, vol. 55, no. 6, pp. 2539–2550, 2008.
- [147] J.-H. Jung, J.-J. Lee, and B.-H. Kwon, "Online diagnosis of induction motors using mcsa," *IEEE Trans. Ind. Electron.*, vol. 53, no. 6, pp. 1842–1852, 2006.

- [148] J. Yang, S. B. Lee, J. Yoo, S. Lee, Y. Oh, and C. Choi, “A stator winding insulation condition monitoring technique for inverter-fed machines,” *IEEE Trans. Power Electron.*, vol. 22, no. 5, pp. 2026–2033, 2007.
- [149] T. M. Wolbank, P. Nussbaumer, H. Chen, and P. E. Macheiner, “Monitoring of Rotor-Bar Defects in Inverter-Fed Induction Machines at Zero Load and Speed,” *IEEE Trans. Ind. Electron.*, vol. 58, pp. 1468–1478, may 2011.
- [150] A. V. Oppenheim, *Discrete-time signal processing*. Pearson Education India, 1999. New York.
- [151] C. B. Rorabaugh, *Digital filter designer’s handbook*. McGraw-Hill, Inc., 1997. New York.
- [152] I. Acoustics, Speech, and S. P. S. D. S. P. Committee, *Programs for digital signal processing*. IEEE, 1979.
- [153] C. Bruzzese and E. Santini, “On the Frequency Dependence of Harmonic Current Side-Band (HCSB) based Rotor Fault Indicators for Three-Phase Cage Machines,” in *2007 IEEE Int. Symp. Diagnostics Electr. Mach. Power Electron. Drives*, pp. 231–235, IEEE, sep 2007.
- [154] V. Climente-Alarcon, J. Antonino-Daviu, M. Riera-Guasp, R. Puche-Panadero, and L. Escobar, “Application of the Wigner–Ville distribution for the detection of rotor asymmetries and eccentricity through high-order harmonics,” *Electr. Power Syst. Res.*, vol. 91, pp. 28–36, oct 2012.
- [155] I. Martin-Diaz, D. Morinigo-Sotelo, O. Duque-Perez, and R. J. Romero-Troncoso, “Early fault detection in induction motors using AdaBoost with imbalanced small data and optimized sampling,” *IEEE Trans. Ind. Appl.*, vol. 53, pp. 3066 – 3075, May-Jun 2016.
- [156] O. Duque-Perez, L. A. Garcia-Escudero, D. Morinigo-Sotelo, P. E. Gardel, and M. Perez-Alonso, “Condition monitoring of induction motors fed by Voltage Source Inverters. Statistical analysis of spectral data,” in *2012 XXth Int. Conf. Electr. Mach.*, pp. 2479–2484, IEEE, sep 2012.
- [157] Boqiang Xu, Liling Sun, and Hui Ren, “A New Criterion for the Quantification of Broken Rotor Bars in Induction Motors,” *IEEE Trans. Energy Convers.*, vol. 25, pp. 100–106, mar 2010.

- [158] B. M. Ebrahimi, J. Faiz, S. Lotfi-fard, and P. Pillay, “Novel indices for broken rotor bars fault diagnosis in induction motors using wavelet transform,” *Mech. Syst. Signal Process.*, vol. 30, pp. 131–145, jul 2012.
- [159] G. M. Joksimovic, J. Riger, T. M. Wolbank, N. Peric, and M. Vasak, “Stator-Current Spectrum Signature of Healthy Cage Rotor Induction Machines,” *IEEE Trans. Ind. Electron.*, vol. 60, pp. 4025–4033, sep 2013.
- [160] T. Fawcett, “An introduction to roc analysis,” *Pattern recognition letters*, vol. 27, no. 8, pp. 861–874, 2006.
- [161] I. Martin-Diaz, D. Morinigo-Sotelo, O. Duque-Perez, and R. J. Romero-Troncoso, “Advances in Classifier Evaluation: Novel Insights for an Electric Data-Driven Motor Diagnosis,” *IEEE Access*, vol. 4, pp. 7028 – 7038, 2016.
- [162] C. H. Yu, “Resampling methods: concepts, applications, and justification,” *Practical Assessment, Research & Evaluation*, vol. 8, no. 19, pp. 1–23, 2003.
- [163] B. Efron and R. Tibshirani, “Improvements on cross-validation: the 632+ bootstrap method,” *Journal of the American Statistical Association*, vol. 92, no. 438, pp. 548–560, 1997.
- [164] I. Martin-Diaz, D. Morinigo-Sotelo, O. Duque-Perez, P. Delgado-Arredondo, D. Camarena-Martinez, and R. Romero-Troncoso, “Analysis of various inverters feeding induction motors with incipient rotor fault using high-resolution spectral analysis,” *Electr. Power Syst. Res.*, vol. 152, pp. 18–26, Nov 2017.
- [165] D. C. Montgomery, G. C. Runger, and N. F. Hubele, *Engineering statistics*. John Wiley & Sons, 2009. Chichester.
- [166] G. Trejo-Caballero, H. Rostro-Gonzalez, R. d. J. Romero-Troncoso, C. H. Garcia-Capulin, O. G. Ibarra-Manzano, J. G. Avina-Cervantes, and A. Garcia-Perez, “Multiple signal classification based on automatic order selection method for broken rotor bar detection in induction motors,” *Electr. Eng.*, pp. 1–10, 2016.
- [167] U. Kamps, *Generalized order statistics*. Wiley Online Library, 1981.
- [168] M. A. Hall, *Correlation-based feature selection for machine learning*. PhD thesis, The University of Waikato, 1999.

- [169] I. Guyon and A. Elisseeff, “An introduction to variable and feature selection,” *Journal of machine learning research*, vol. 3, no. Mar, pp. 1157–1182, 2003.
- [170] Y. Saeys, I. Inza, and P. Larrañaga, “A review of feature selection techniques in bioinformatics,” *Bioinformatics*, vol. 23, no. 19, 2007.
- [171] I. Guyon, S. Gunn, M. Nikravesh, and L. A. Zadeh, *Feature extraction: foundations and applications*, vol. 207. Springer, 2008. New York, USA.
- [172] D. C. Montgomery, *Design and analysis of experiments*. John Wiley & Sons, 2008. Chichester.
- [173] M. Robnik-Sikonja and I. Kononenko, “Theoretical and empirical analysis of relieff and rrelieff,” *Machine learning*, vol. 53, no. 1-2, pp. 23–69, 2003.
- [174] K. Kira and L. A. Rendell, “A practical approach to feature selection,” in *Proceedings of the ninth international workshop on Machine learning*, pp. 249–256, 1992.
- [175] I. Kononenko, “Estimating attributes: analysis and extensions of relief,” in *European conference on machine learning*, pp. 171–182, Springer, 1994.
- [176] L. Breiman, “Random forests,” *Machine learning*, vol. 45, no. 1, pp. 5–32, 2001.
- [177] Y. Sun, A. K. Wong, and M. S. Kamel, “Classification of imbalanced data: A review,” *Int. J Pattern Recogn.*, vol. 23, no. 04, pp. 687–719, 2009.
- [178] Haibo He and E. Garcia, “Learning from Imbalanced Data,” *IEEE Trans. Knowl. Data Eng.*, vol. 21, pp. 1263–1284, sep 2009.
- [179] N. V. Chawla, K. W. Bowyer, L. O. Hall, and W. P. Kegelmeyer, “Smote: synthetic minority over-sampling technique,” *J. Artif. Intell. Res.*, vol. 16, pp. 321–357, 2002.
- [180] T. M. Ha and H. Bunke, “Off-line, handwritten numeral recognition by perturbation method,” *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 19, no. 5, pp. 535–539, 1997.
- [181] Y. Freund and R. E. Schapire, “A decision-theoretic generalization of on-line learning and an application to boosting,” *J. Comput. Syst. Sci.*, vol. 1, no. 55, pp. 119–139, 1997.
- [182] R Core Team, *R: A Language and Environment for Statistical Computing*. R Foundation for Statistical Computing, Vienna, Austria, 2013.