



UNIVERSITAT  
POLITÈCNICA  
DE VALÈNCIA



ESCUELA TÉCNICA  
SUPERIOR INGENIERÍA  
INDUSTRIAL VALENCIA

Curso Académico:

## RESUMEN

Los rodamientos son elementos usados en gran cantidad de máquinas y dependiendo de su función, pueden variar de tamaño y de tipo. Detectar fallos en rodamientos puede ser muy útil, ya que su mal funcionamiento puede provocar deterioro en otros componentes de las máquinas, pudiendo ocasionar fallos críticos en el largo plazo.

El objetivo de este TFG es entrenar y validar algoritmos de machine learning con datos de vibraciones en rodamientos que presentan un buen estado y otros que tienen distintos posibles defectos, con variaciones en el tamaño del fallo.

Para poder entrenar los algoritmos, previamente se analizarán señales vibratorias de rodamientos en distintos estados. Estas señales serán obtenidas de la web de "Case Western Reserve University Bearing Data Center Website". Trabajando con la señal se obtendrán las características o parámetros necesarios que permitan clasificar y diferenciar entre los posibles distintos fallos que puede sufrir el rodamiento. Estos parámetros serán introducidos en los distintos algoritmos de Machine learning, para que a partir de ellos, el algoritmo pueda indicar cual es el estado del rodamiento.

Los algoritmos se entrenarán y exportarán usando la herramienta Classification Learner de Matlab. Esta herramienta ofrece distintos algoritmos: Árboles de decisión, K vecinos más cercanos, Análisis discriminante, Algoritmos de Naïve Bayes, Máquinas de vector soporte, Árboles potenciados y Árboles empaquetados. Una vez entrenados, los algoritmos deberán ser validados con otros datos (datos de test) para comprobar que son válidos y que no ocurre el fenómeno del overfitting o sobreajuste. Se comparará la precisión de los algoritmos entre sí, estudiando las diferencias de precisión entre estos.

Después los algoritmos que obtengan una mayor precisión al clasificar el estado de los rodamientos, serán analizados a fondo y modificados con el objetivo de incrementar su precisión, siempre que sea posible.

**Palabras Clave:** Rodamiento, vibraciones, machine learning, diagnóstico de fallos, Matlab, análisis de señales, sobreajuste

## RESUM

Els rodaments son elements utilitzats en un gran nombre de màquines i en funció de la seua tarea a realitzar, poden ser de diferents tipus i tamanys. Detectar fallades en rodaments pot ser molt útil, ja que un mal funcionament d'aquests pot provocar una deterioració en altres components de les màquina, amb la possibilitat de arribar a provocar fallades crítiques.

El objectiu del TFG es entrenar i validar algoritmes de machine learning amb dates de vibracions en rodaments que presenten un bon estat i altres que tinguen distints possibles defectes, amb variacions en el tamany del defecte.

Per a poder entrenar els algoritmes, prèviament s'analitzaran senyals vibratoris de rodaments en diferents estats. Aquests senyals seran obtinguts de la web de "Case Western Reserve University Bearing Data Center Website". Treballant amb la senyal, s'obtindran les característiques o paràmetres necessaris que permeten classificar i diferenciar entre els possibles diferents fallades que pot patir el rodament. Aquests paràmetres seran introduïts en els diferents algoritmes de Machine learning perquè a partir d'ells, l'algoritme puga indicar com és l'estat del rodament.

Els algoritmes s'entrenaran i exportaran usant l'eina Classification Learner de Matlab. Aquesta eina ofereix diferents algoritmes: Arbres de decisió, K veïns més pròxims, Anàlisi discriminant, Algoritmes de Naïve Bayes, Màquines de vector soporte, Arbres potenciats i Arbres empaquetats. Una vegada entrenats, els algoritmes hauran de ser validats amb altres dades, (dades de test) per a comprovar que són vàlids i que no ocorre el fenomen del overfitting. Es comparará la precisió dels algoritmes entre si, estudiant les diferències de precisió entre aquests.

Després els algoritmes que obtinguen una major precisió en classificar l'estat dels rodaments, seran analitzats a fons i modificats amb l'objectiu d'incrementar la seua precisió, sempre que siga possible.

**Paraules clau:** Rodaments, vibracions, machine learning, diagnostic de fallades, Matlab, anàlisi de senyals, overfitting

## **ABSTRACT**

Bearings are used in a lot of industrial machines and their size and model can change depending of their function. Bearing faults diagnosis can be very useful, because a faulty bearing can cause deterioration in other components of machines which may lead to catastrophic failures.

The objective of this final degree project is to train and validate machine learning algorithms with normal bearing vibration data and faulty bearing vibration data, with different fault size.

To train the algorithms, vibratory signals of different bearings (normal and defective) will be analysed previously. This signals will be obtained from the "Case Western Reserve University Bearing Data Center Website". Work with the signal will be done in order to obtain the necessary parameters or features, to classify correctly between the possible bearing faults. This features will be the input data for the different Machine learning algorithms.

The algorithms will be trained and exported using the Clasification Learner Matlab toolbox. This toolbox has different algorithms: Decision trees, K Nearest Neighbours, Discriminant analysis, Naïve Bayes algorithms, Support vector machine, Boosted trees and Bagged trees. Once the algorithms had been trained, these will be validated with other data (test data) to prove that there is no overfitting. The accuracy of the different algorithms will be compared, studying the variations of it in different algorithms.

Afterwards the more accurate algorithms will be deeper analysed and modified to obtain, if it is possible, a better accuracy.

**Keywords:** Bearings, vibrations, machine learning, fault diagnosis, Matlab, signal analysis, overfitting

## ÍNDICE

I.	MEMORIA .....	1
1.	Introducción .....	2
1.1.	Rodamientos .....	2
1.2.	Técnicas de diagnóstico predictivo .....	3
1.3.	Diagnóstico predictivo de fallos en rodamientos.....	4
1.4.	Machine Learning .....	6
1.5.	Objetivos.....	8
2.	Obtención de datos .....	9
2.1.	Banco de ensayo.....	9
2.2.	Características de los rodamientos .....	10
2.3.	Formato de los datos.....	12
3.	Análisis de la señal.....	13
3.1.	Métodos de análisis de vibraciones .....	13
3.2.	Aplicación de métodos de análisis de vibraciones .....	15
4.	Obtención de características .....	35
5.	Entrenamiento y validación de algoritmos .....	38
5.1.	Resultados del entrenamiento .....	38
5.2.	Resultados de la validación .....	46
5.3.	Análisis de resultados.....	49
6.	Conclusiones.....	54
II.	CÁLCULOS.....	56
1.	Código del análisis de vibraciones del rodamiento 1.....	57
2.	Código del análisis de vibraciones del rodamiento 2.....	62
3.	Código obtención de características con ancho de banda personalizado .....	64
4.	Código obtención de características sin ancho de banda personalizado.....	65
5.	Código de la función helperPlotCombs .....	66
III.	PRESUPUESTO .....	67

1. Presupuestos parciales.....	68
2. Presupuesto total.....	69
REFERENCIAS.....	70

### ÍNDICE DE ILUSTRACIONES

Ilustración 1. Partes de un rodamiento rígido de bolas. Fuente: (SPORT, 2021).....	2
Ilustración 2. Banco de ensayo. Fuente: (University, s.f.).....	10
Ilustración 3. Rodamiento 6205-2RS JEM SKF. Fuente: (Made-in-China, s.f.).....	10
Ilustración 4. Señal completa y ampliada del rodamiento 1 en buen estado.....	16
Ilustración 5. Señal completa y ampliada del rodamiento 1 con fallo en la pista interna.....	16
Ilustración 6. Señal completa y ampliada del rodamiento 1 con fallo en la pista externa.....	17
Ilustración 7. Señal completa y ampliada del rodamiento 1 con fallo en la bola.....	17
Ilustración 8. Espectro de potencia de la señal del rodamiento 1 normal y ampliación de la región de bajas frecuencias.....	18
Ilustración 9. Espectro de potencia de la señal del rodamiento 1 con fallo en la pista interna y ampliación de la zona de bajas frecuencias.....	18
Ilustración 10. Espectro de potencia de la señal del rodamiento 1 con fallo en la pista externa y ampliación de la zona de bajas frecuencias.....	19
Ilustración 11. Espectro de potencia de la señal del rodamiento 1 con fallo en la bola y ampliación de la zona de bajas frecuencias.....	19
Ilustración 12. Señal vibratoria en el tiempo junto con la envolvente de la señal para fallo en la pista interna del rodamiento 1.....	20
Ilustración 13. Espectro de la envolvente de la señal del rodamiento 1 con fallo en la pista interna junto con los múltiplos de BPFI.....	21
Ilustración 14. Señal vibratoria en el tiempo junto con la envolvente de la señal para el rodamiento 1 en buen estado.....	22
Ilustración 15. Espectro de la envolvente de la señal del rodamiento 1 en buen estado junto con los múltiplos de BPFI, BPFO y BSF.....	23
Ilustración 16. Señal vibratoria en el tiempo junto con la envolvente de la señal para fallo en la pista externa del rodamiento 1.....	23
Ilustración 17. Espectro de la envolvente de la señal del rodamiento 1 con fallo en la pista externa junto con los múltiplos de BPFO.....	24
Ilustración 18. Señal vibratoria en el tiempo junto con la envolvente de la señal del rodamiento 1 para fallo de diámetro 0,007 pulgadas en la bola.....	24
Ilustración 19. Señal vibratoria en el tiempo junto con la envolvente de la señal del rodamiento 1 para fallo de diámetro 0,021 pulgadas en la bola.....	25
Ilustración 20. Espectro de la envolvente de la señal del rodamiento 1 con fallo de diámetro 0,007 pulgadas en la bola junto con los múltiplos de BSF.....	26
Ilustración 21. Kurtograma de la señal del rodamiento 1 en buen estado.....	27
Ilustración 22. Espectro de la envolvente de la señal de rodamiento 1 en buen estado usando el ancho de banda óptimo según el kurtograma.....	27
Ilustración 23. Kurtograma de la señal del rodamiento 1 con fallo en la pista interna.....	28

Ilustración 24. Espectro de la envolvente de la señal de rodamiento 1 con fallo en la pista interna usando el ancho de banda óptimo según el kurtograma.....	29
Ilustración 25. Kurtograma de la señal del rodamiento 1 con fallo en la pista externa .....	29
Ilustración 26. Espectro de la envolvente de la señal de rodamiento 1 con fallo en la pista exterior usando el ancho de banda óptimo según el kurtograma.....	30
Ilustración 27. Kurtograma de la señal del rodamiento 1 con fallo en la bola .....	30
Ilustración 28. Espectro de la envolvente de la señal de rodamiento 1 con fallo en la bola usando el ancho de banda óptimo según el kurtograma .....	31
Ilustración 29. Espectro de la envolvente del rodamiento 2 en buen estado sin usar el ancho de banda sugerido por el kurtograma y usándolo .....	32
Ilustración 30. Espectro de la envolvente del rodamiento 2 con fallo en la pista interna sin usar el ancho de banda sugerido por el kurtograma y usándolo .....	32
Ilustración 31. Kurtograma obtenido para fallo en la pista interna del rodamiento 2 .....	33
Ilustración 32. Espectro de la envolvente de la señal de fallo en la pista externa del rodamiento 2 sin usar el ancho de banda sugerido por el kurtograma y usándolo.....	34
Ilustración 33. Imagen de parte de la tabla obtenida con las características y una etiqueta indicando el estado del rodamiento para cada archivo de datos.....	36
Ilustración 34. Características obtenidas representadas en el plano .....	37
Ilustración 35. Matriz de confusión de los árboles de decisión entrenados.....	39
Ilustración 36. Matriz de confusión del discriminante lineal entrenado .....	40
Ilustración 37. Matriz de confusión del discriminante cuadrático entrenado .....	40
Ilustración 38. Matriz de confusión del algoritmo Naïve Bayes de Kernel entrenado.....	41
Ilustración 39. Matriz de confusión del SVM lineal entrenado .....	42
Ilustración 40. Matriz de confusión del SVM Gaussiano fino entrenado.....	42
Ilustración 41. Matriz de confusión del SVM Gaussiano grueso entrenado .....	43
Ilustración 42. Matriz de confusión del KNN medio entrenado.....	44
Ilustración 43. Matriz de confusión del KNN grueso entrenado .....	44
Ilustración 44. Matriz de confusión del KNN cúbico entrenado .....	45
Ilustración 45. Matriz de confusión del KNN coseno entrenado .....	45
Ilustración 46. Matriz de confusión del discriminante cuadrático validado .....	46
Ilustración 47. Matriz de confusión de los algoritmos Naïve Bayes validados .....	47
Ilustración 48. Matriz de confusión del SVM Gaussiano grueso validado .....	48
Ilustración 49. Matriz de confusión del KNN grueso validado .....	48
Ilustración 50. Árbol de decisión obtenido .....	49
Ilustración 51. Representación gráfica del algoritmo SVM. Fuente: (The MathWorks) .....	51
Ilustración 52. Representación de datos de la clase normal frente al resto.....	51
Ilustración 53. Representación de datos de la clase pista interna frente al resto .....	52
Ilustración 54. Representación de datos de la clase pista externa frente al resto .....	52

## ÍNDICE DE TABLAS

Tabla 1. Frecuencias características de fallo en rodamientos. Fuente: (Barszcz, 2019) .....	5
Tabla 2. Especificaciones de los rodamientos del eje que transmite par y del ventilador. Fuente: (University, s.f.) .....	11
Tabla 3. Especificaciones de los fallos .....	11
Tabla 4. Precisiones de los árboles de decisión entrenados .....	39
Tabla 5. Precisiones de los algoritmos de análisis discriminante entrenados .....	39
Tabla 6. Precisiones de los algoritmos de Naïve Bayes entrenados.....	41
Tabla 7. Precisiones de los algoritmos SVM entrenados .....	41
Tabla 8. Precisiones de los algoritmos KNN entrenados .....	43
Tabla 9. Precisiones de los árboles de decisión en la validación.....	46
Tabla 10. Precisiones de los algoritmos de análisis discriminante en la validación .....	46
Tabla 11. Precisiones de los algoritmos de Naïve Bayes en la validación .....	47
Tabla 12. Precisiones de los algoritmos SVM en la validación .....	47
Tabla 13. Precisiones de los algoritmos KNN en la validación .....	48
Tabla 14. Número de vecinos y medida de distancia para los distintos KNN .....	53
Tabla 15. Amplitudes de armónicos de frecuencia BPFI y BPFO para fallos en la pista interna y externa para el rodamiento del eje que transmite par (DE) y para el rodamiento del ventilador (FE) cuando se ha calculado la envolvente de la señal usando ancho de banda óptimo y sin hacer uso de este .....	54
Tabla 16. Presupuesto de los recursos materiales.....	68
Tabla 17. Presupuesto de los recursos humanos.....	68
Tabla 18. Presupuesto de los gastos de envío de recursos materiales.....	69
Tabla 19. Presupuesto total del trabajo .....	69





# I. MEMORIA

## 1. Introducción

### 1.1. Rodamientos

Los rodamientos son elementos usados en gran cantidad de máquinas y dependiendo de su función, pueden variar de tamaño y de tipo. Estos elementos se utilizan con el objetivo de permitir el giro de los ejes. Detectar fallos en rodamientos puede ser muy útil, ya que su mal funcionamiento puede provocar deterioro en otros componentes de las máquinas, pudiendo ocasionar fallos críticos en el largo plazo.

Como criterio para la clasificación de rodamientos se suele utilizar la dirección de la carga aplicada. De esta forma cuando la carga es radial, el rodamiento se clasifica como radial y si la carga que soporta el rodamiento tiene dirección axial, se trata de un rodamiento axial. Sin embargo, también se puede usar la forma de los elementos rodantes como criterio, ya que pueden haber rodamientos de bolas o rodillos.

El rodamiento del banco de trabajo sobre el que se va a hacer en análisis es un rodamiento radial rígido de bolas de ranura profunda, este es uno de los tipos más comunes de rodamientos en la industria. Están diseñados para transmitir cargas radiales, pero también pueden soportar cargas axiales de baja magnitud. Una ventaja de estos es que pueden operar a altas velocidades ya tienen una fricción reducida.

En la siguiente imagen se ilustra las distintas partes de un rodamiento. Pueden verse sus pistas externa e interna dentro de las cuales se encuentran los elementos rodantes que en este caso son bolas. Las bolas están envueltas por una jaula, la cual mantiene la posición de estas. Por último, se puede ver la tapa del rodamiento, la cual evita que entren elementos externos en el rodamiento y a su vez evita que el lubricante se salga.




Ilustración 1. Partes de un rodamiento rígido de bolas. Fuente: (SPORT, 2021)

“La vida de un rodamiento puede verse afectada por distintos parámetros como:

- Fatiga
- Desgaste
- Corrosión
- Lubricación insuficiente
- Suciedad
- Errores de montaje
- Deformaciones elásticas y térmicas
- Errores de lubricación de elementos circundantes y de las partes del rodamiento”

(BESA GONZÁLVIZ & VALERO CHULIÁ, 2016)

Al ser elementos críticos en las máquinas rotativas, es interesante conocer su estado, para que en caso de fallo debido a alguno de estos motivos, pueda ser detectado lo antes posible y reemplazado por uno en buen estado. Para conseguir esto, se pueden utilizar técnicas de mantenimiento y diagnóstico predictivo de fallos.

## 1.2. Técnicas de diagnóstico predictivo

El diagnóstico predictivo es la herramienta o proceso que utiliza el mantenimiento predictivo para detectar fallos en equipos industriales. El objetivo del mantenimiento predictivo es conseguir la máxima disponibilidad de la máquina y evitar interrupciones de funcionamiento no planificadas, por esto utiliza el diagnóstico predictivo.

Para detectar fallos en los componentes de las máquinas se pueden utilizar distintos métodos o técnicas dentro del diagnóstico predictivo. La técnica usada en este trabajo es en análisis de vibraciones, pero en este apartado se describirán brevemente otras técnicas importantes además de esta.

### Análisis de vibraciones

El análisis de vibraciones es una de las técnicas más utilizadas en el diagnóstico predictivo. Esto es debido a que usa acelerómetros para captar señales vibratorias y estos son sensores relativamente baratos.

Este método es el que se va a usar en este trabajo y por lo tanto será tratado en siguientes apartados.

### Análisis de ultrasonidos

El análisis de ultrasonidos es una extensión del análisis acústico. Este método utiliza el fenómeno de la propagación de ondas que se produce en muchos fenómenos físicos donde ocurren impactos de

corta duración. Dentro de los rodamientos se puede utilizar para detectar lubricación incorrecta de rodamientos. Su inconveniente es que utiliza tecnología de un precio más elevado al que se usa en el análisis de vibraciones.

#### Análisis de aceites

La lubricación con aceite permite reducir la fricción entre los componentes de la máquina, alargando la vida útil de estos. Normalmente cuando el lubricante está desgastado, es decir, contiene contaminación proveniente de distintas partes de la máquina, tan solo se cambia tal y como indican las recomendaciones del fabricante. Sin embargo, las técnicas predictivas de análisis de aceites aprovechan que la degradación del aceite es a su vez síntoma de degradación de partes de la máquina.

El inconveniente de este método es que no permite conocer la localización del fallo.

#### Análisis de datos SCADA

“SCADA es el acrónimo de Supervisory Control and Data Acquisition (supervisión, control y adquisición de datos).” (Wikipedia, s.f.)

Esta técnica consiste en monitorizar diferentes datos que puedan ser de interés, que pueden ser externos a la máquina o internos, para así poder detectar fallos. Existen múltiples formas de analizar los datos que se obtienen de este análisis, una de ellas tiene que ver con en este trabajo y es el uso de algoritmos de Inteligencia artificial que automaticen el proceso de detección de fallos.

### 1.3. Diagnóstico predictivo de fallos en rodamientos

El diagnóstico predictivo es uno de los conceptos sobre los que se va a desarrollar este trabajo. Dado que se van a diagnosticar distintos tipos de fallos en rodamientos, es importante entrar en ciertos conceptos teóricos.

El deterioro de cada una de las partes de un rodamiento (pista externa, pista interna y elementos rodantes, etc.) viene asociado a la aparición de armónicos de las frecuencias correspondientes a la localización del fallo. Estas frecuencias son:

- BPFO (Ball Pass Frequency of the Outer race) o frecuencia de deterioro de la pista exterior. Es la frecuencia donde un defecto generará una señal si el problema está en la pista exterior. “Es equivalente al número de bolas o rodillos que pasan por un punto de la pista exterior por revolución.” (Fernandez, 2021)
- BPFI (Ball Pass Frequency of the Inner race) o frecuencia de deterioro de la pista interior. Es la frecuencia donde un defecto generará una señal si el problema está en la pista interior. “Es equivalente al número de bolas o rodillos que pasan por un punto de la pista interior por revolución.” (Fernandez, 2021)

- BSF (Ball Spin Frequency) o frecuencia de deterioro de los elementos rodantes. Es la frecuencia de los elementos rodantes bolas o rodillos. “Equivale al número de giros que realiza una bola o rodillo del rodamiento por revolución.” (Fernandez, 2021)
- FTF (Fundamental Train Frequency) o frecuencia de deterioro de la jaula. Es la frecuencia fundamental de giro de la jaula. “Es equivalente al número de giros que realiza la jaula del rodamiento por revolución.” (Fernandez, 2021)

Si el rodamiento sufre varios de estos tipos de fallos simultáneamente, aparecerán los distintos armónicos correspondientes a cada fallo en sus respectivas frecuencias de fallo.

Los rodamientos pueden sufrir otros fallos distintos a los expuestos, pero no van a ser tratados en este trabajo.

Los defectos que se van a diagnosticar son de desconchado, los cuales ocurren por fatiga.

Las fórmulas que permiten calcular las frecuencias de fallo expuestas para cada rodamiento son las de la tabla 1:

Descripción del fallo	Frecuencia característica	Localización del fallo
Ball Pass Frequency of the Outer race (BPFO)	$\frac{nf_r}{2} \left(1 - \frac{d}{D} \cos\phi\right)$	Pista externa
Ball Pass Frequency of the Inner race (BPFI)	$\frac{nf_r}{2} \left(1 + \frac{d}{D} \cos\phi\right)$	Pista interna
Ball Spin Frequency (BSF)	$\frac{f_r D}{d} \left(1 - \frac{d^2}{D^2} \cos^2\phi\right)$	Elemento rodante
Fundamental Train Frequency (FTF)	$\frac{f_r}{2} \left(1 - \frac{d}{D} \cos\phi\right)$	Jaula

*Tabla 1. Frecuencias características de fallo en rodamientos. Fuente: (Barszcz, 2019)*

Donde  $d$  es el diámetro de la bola,  $D$  es el diámetro de paso,  $f_r$  es la velocidad del eje,  $n$  es el número de elementos rodantes y  $\phi$  es el ángulo de contacto del rodamiento.

Puede observarse que las frecuencias de fallo dependen del ángulo de contacto, por lo tanto si hay una pequeña variación de este las frecuencias de fallo pueden variar, haciendo que la identificación del defecto en el espectro sea más difícil, ya que los picos de mayor magnitud caerán en frecuencias distintas del espectro a las calculadas de antemano.

Una vez expuestos los distintos tipos de fallos más comunes que se pueden dar en rodamientos, se va a explicar las distintas fases de deterioro que sufre el rodamiento causadas por el desarrollo del fallo.

- **Fase inicial:** El defecto tiene un tamaño reducido y cuando el rodamiento gira se generan impactos los cuales captan los acelerómetros, pero en el espectro no se pueden identificar lecturas de vibración en las frecuencias características de deterioro, tan solo se visualizan picos de mayor magnitud en frecuencias altas, que suelen ser las frecuencias naturales o de resonancia del rodamiento.
- **Fase intermedia:** En este momento el fallo va incrementando de tamaño, por lo que ya se pueden apreciar los armónicos de frecuencias características de fallo, mientras que la vibración de frecuencia natural del rodamiento se mantiene. En esta etapa el fallo es local, ya que es más pequeño que el rodamiento y al ir creciendo, mientras siga siendo un fallo local, la magnitud de los armónicos va incrementando.
- **Fase final:** En esta última fase, el fallo pasa a ser extendido, ya que su tamaño es mayor que el del rodamiento y comienzan a aparecer holguras y roces en este. Las señales vibratorias generadas por el fallo son mucho más complejas y al tener más ruido los armónicos de las frecuencias de fallo disminuyen y quedan enmascarados.

#### 1.4. Machine Learning

Para poder clasificar los distintos datos de rodamientos y determinar cuales están en buen estado o cuales tienen algún fallo y en este caso, de que tipo de fallo se trata, se ha recurrido a algoritmos de Machine learning.

Machine learning es un subcampo de las ciencias de la computación, el cual pertenece al ámbito de

la Inteligencia artificial y cuyo objetivo es crear sistemas que aprenden automáticamente. Los algoritmos de machine learning usan métodos computacionales para extraer información de los datos que se introducen en el algoritmo sin depender de una ecuación determinada como modelo y al aumentar el número de datos que introducimos al algoritmo, este se adapta y mejora sus resultados.

Hoy en día con el incremento en la cantidad de datos que los ordenadores pueden almacenar y manejar, el Machine learning se ha convertido en una herramienta muy útil para resolver problemas o tomar mejores decisiones. Varios de los sectores donde se usan algoritmos de este tipo son: reconocimiento facial, detección de movimiento, fabricación, mantenimiento predictivo, etc.

Existen dos tipos de técnicas a la hora de obtener algoritmos de Machine learning, el aprendizaje no supervisado y el aprendizaje supervisado.

El aprendizaje no supervisado consiste en obtener patrones no visibles a simple vista en los datos que introducimos al algoritmo, mientras que el aprendizaje supervisado trata de entrenar un modelo

con valores conocidos de entrada y de salida, para así poder predecir valores de salida al introducir determinados datos de entrada. De estos dos tipos de Machine learning, el utilizado para este trabajo ha sido el aprendizaje supervisado.

Dentro del aprendizaje supervisado se utilizan dos tipos técnicas para obtener modelos: técnicas de regresión y de clasificación.

Las técnicas de regresión sirven para predecir el valor de variables continuas en el tiempo, sin embargo, en este trabajo se han usado técnicas de clasificación ya que estas sirven para predecir variables discretas, es decir, si el rodamiento está en buen estado, o tiene un fallo en la pista interna, pista externa o en alguna bola.

Para generar y entrenar algoritmos se ha usado la herramienta Classification Learner de Matlab, la cual nos permite entrenar distintos algoritmos. A continuación, se presentarán los distintos algoritmos que ofrece la herramienta y se explicarán brevemente.

- **Árboles de decisión.** Algoritmo que en función de unos datos de entrada (inputs) proporciona una solución (output) siguiendo un conjunto de condiciones o decisiones las cuales van desde un nodo raíz, que es el inicio del árbol, hasta un nodo terminal. Las condiciones en cada nodo y el número de nodos se determinan al entrenar el algoritmo. Algunas de las ventajas de este algoritmo son: que es fácil de interpretar, utilizan poco espacio en memoria y se pueden ajustar a patrones no lineales. Como desventajas: es sensible a datos anómalos y no suelen ofrecer precisiones muy elevadas.
- **Análisis discriminante.** Este tipo de algoritmos clasifica datos buscando combinaciones lineales de características o predictores. Asumen que los datos pertenecientes a cada clase siguen una distribución de Gauss. Las distribuciones de Gauss están caracterizadas por ciertos parámetros los cuales se calculan para cada clase al entrenar este tipo de algoritmos. A partir de estos parámetros se obtienen los límites que separan regiones de datos de distintas clases y gracias a estos límites se clasifican nuevos datos de entrada.
- **Algoritmos de Naïve Bayes.** Son algoritmos bastante simples y fáciles de interpretar. Utilizan el “Teorema de Bayes” para decidir a que clase pertenecen los datos de entrada. Al usar este teorema se asume que las variables predictoras son independientes entre sí, es decir, que la presencia de una variable o predictor en los datos no está correlacionada con ningún otro predictor. Al introducir nuevos datos al algoritmo, este los clasificará en la clase a la que tengan más probabilidad de pertenecer, calculando esta probabilidad mediante el teorema de Bayes. El teorema de Bayes es el siguiente:

$$P(A|B) = \frac{P(B|A) P(A)}{P(B)}$$

Donde,

$P(A)$  es la probabilidad a priori de A

$P(B)$  es la probabilidad a priori de B

$P(B|A)$  es la probabilidad de que ocurra B si ha ocurrido A

$P(A|B)$  es la probabilidad de que ocurra A si ha ocurrido B



Este algoritmo es útil para bancos de datos pequeños con muchas variables predictoras diferentes y cuando haya posibilidad de que el algoritmo se enfrente a datos de entrada poco similares a los que ha usado para entrenar.

- **Máquinas de vectores de soporte o máquinas de vector soporte.** Estos algoritmos tratan de obtener la "frontera" que separa de mejor manera las distintas clases. A estas fronteras entre clases se les llama hiperplanos, el objetivo es obtener un hiperplano que separe los datos de distintas clases dejando el mayor margen posible entre ellas. Los puntos desde los cuales se mide la distancia o margen son los llamados vectores soporte, que son los puntos o punto que más próximos están del hiperplano.  
Este algoritmo se suele usar cuando se tienen dos clases posibles para clasificar los datos de entrada (aunque también se puede usar para problemas con más de dos clases, utilizando el mismo concepto teórico que se usa al clasificar entre dos clases, pero el problema pasa a ser más complejo).
- **K vecinos más cercanos.** Este algoritmo clasifica los datos en función de la clase a la que pertenezcan datos similares o próximos a él, a estos datos se les llama vecinos más cercanos. A la hora de predecir datos nuevos el algoritmo asume que los datos cercanos entre si son de la misma clase. Los dos parámetros más importantes en este algoritmo son el número de vecinos que tiene en cuenta el algoritmo para hacer nuevas predicciones y el tipo de medida de distancia que se utiliza. Las medidas de distancia más comunes son: distancia euclídea, similitud coseno, distancia de Chebychev o distancia de Minkowski.

## 1.5. Objetivos

Una vez introducidos todos los conceptos que se van desarrollar en mayor profundidad y se van a utilizar a lo largo de este trabajo, es posible explicar el objetivo de este.

El objetivo es conseguir un algoritmo el cual clasifique el estado del rodamiento entre los siguientes:

- Normal
- Fallo pista interna
- Fallo pista externa
- Fallo en la bola

Para ello se utilizarán señales obtenidas de un banco de ensayo, las cuales serán analizadas basándose en métodos de análisis de vibraciones. Una vez se hayan obtenido las variables que interesen, estas serán utilizadas en diferentes algoritmos de Machine Learning, con el propósito de obtener la precisión de clasificación más alta posible. Como herramienta para realizar el análisis de las señales y llevar a cabo todo el desarrollo de los algoritmos se utilizará Matlab.

## 2. Obtención de datos

Para obtener los datos de las vibraciones necesarios para poder entrenar y validar los diferentes algoritmos que se verán a lo largo de este trabajo, se ha utilizado la página web de Case Western Reserve University Bearing Data Center Website. Esta web proporciona datos de rodamientos en buen estado y otros con defectos.

### 2.1. Banco de ensayo

Como se puede ver en la imagen, el banco de test está formado por un motor eléctrico de 2 HP, un codificador de par, el cual obtiene la velocidad y carga del motor, un dinamómetro y electrónica de control, la cual no se ve en la imagen. Los rodamientos de los cuales se obtienen los datos son el soporta al eje del motor y el del ventilador. De aquí en adelante serán nombrados como rodamiento 1 y 2 respectivamente.

Las señales vibratorias fueron obtenidas mediante acelerómetros, colocados en alojamientos del motor, disponiéndolos en el extremo donde se transmite el par al eje y en el extremo donde está ubicado el ventilador del motor. Las señales vibratorias se pueden descargar en formato Matlab y fueron obtenidas algunas 12000 y otras a 48000 muestras por segundo, pero en este trabajo solo se han usado las de 12000 muestras por segundo.




Ilustración 2. Banco de ensayo. Fuente: (University, s.f.)

## 2.2. Características de los rodamientos

Se usaron dos tipos de rodamientos: SKF y NTN. Usando descarga eléctrica se introdujeron defectos en la pista interna, externa y en bolas del rodamiento. Para los SKF se crearon defectos de 7, 14 y 21 milipulgadas de diámetro, lo cual corresponde a 0,18, 0,35 y 0,53 milímetros respectivamente. Para los NTN el tamaño de defecto 28 y 40 milipulgadas, sin embargo, en la página web no se especifican los datos necesarios para poder realizar el análisis de vibraciones del rodamiento NTN, por lo tanto, solo se han usado los datos de test realizados con rodamientos del tipo SKF.



Ilustración 3. Rodamiento 6205-2RS JEM SKF.  
Fuente: (Made-in-China, s.f.)

## Diseño de algoritmos de diagnóstico de fallos en rodamientos basados en métodos de machine learning aplicados al análisis de vibraciones

### Bearing Information

**Drive end bearing:** 6205-2RS JEM SKF, deep groove ball bearing

Size: (inches)

Inside Diameter	Outside Diameter	Thickness	Ball Diameter	Pitch Diameter
0.9843	2.0472	0.5906	0.3126	1.537

Defect frequencies: (multiple of running speed in Hz)

Inner Ring	Outer Ring	Cage Train	Rolling Element
5.4152	3.5848	0.39828	4.7135

**Fan end bearing:** 6203-2RS JEM SKF, deep groove ball bearing

Size: (inches)

Inside Diameter	Outside Diameter	Thickness	Ball Diameter	Pitch Diameter
0.6693	1.5748	0.4724	0.2656	1.122

Defect frequencies: (multiple of running speed in Hz)

Inner Ring	Outer Ring	Cage Train	Rolling Element
4.9469	3.0530	0.3817	3.9874

*Tabla 2. Especificaciones de los rodamientos del eje que transmite par y del ventilador. Fuente: (University, s.f.)*

Estas son las especificaciones de los fallos que van a ser usados para entrenar y validar los algoritmos:

Localización del fallo	Diámetro	Profundidad
Pista interna	0,007	0,011
Pista interna	0,014	0,011
Pista interna	0,021	0,011
Pista externa	0,007	0,011
Pista externa	0,014	0,011
Pista externa	0,021	0,011
Bola	0,007	0,011
Bola	0,014	0,011
Bola	0,021	0,011

*Tabla 3. Especificaciones de los fallos*

Donde las dimensiones de diámetro y profundidad están en pulgadas.

### 2.3. Formato de los datos

Para los dos rodamientos del banco y tanto para el caso de rodamiento sin defectos, como para cada tamaño de defecto distinto, se dispone de datos con 4 cargas diferentes para el motor: 0, 1, 2 y 3 HP, las cuales equivalen a velocidades de giro de 1797, 1772, 1750 y 1730 rpm respectivamente.

En el caso de los fallos en la carrera externa del rodamiento, hay experimentos con defectos ubicados en la carrera exterior del rodamiento (viendo el rodamiento como un reloj) a las 3 (perpendicular a la zona de carga) a las 6 (en la zona de carga) y a las 12 (opuesto a la zona de carga).

Al abrir cualquiera de los archivos de datos en Matlab, en el Workspace aparece una variable con la velocidad del motor en rpm para ese ensayo, varios vectores con los valores registrados en cada instante de muestreo por los distintos acelerómetros y la frecuencia de muestreo. Las siguientes abreviaciones indican a que acelerómetro corresponden los datos:

- DE - datos del acelerómetro colocado donde se transmite par al eje
- FE – datos del acelerómetro colocado en el ventilador
- BA – datos del acelerómetro colocado en la base

### 3. [Análisis de la señal](#)

#### 3.1. Métodos de análisis de vibraciones

El objetivo de este apartado es poder diferenciar entre las señales vibratorias de rodamientos para los distintos estados contemplados (normal, fallo pista interna, fallo pista externa y fallo en la bola)

Normalmente, es difícil obtener características o parámetros de una señal vibratoria original que permitan determinar cual es el estado del rodamiento, es por esto que se utilizan estos métodos de análisis de señales vibratorias, los cuales permiten obtener características para clasificar el estado del rodamiento a partir de su señal vibratoria. Los métodos que se van a exponer son: análisis de frecuencia y análisis de envolvente.

#### **Análisis de frecuencia**

El análisis de frecuencia trata de obtener la señal en el dominio de la frecuencia, en vez de en el dominio del tiempo, que es en el que la obtienen los acelerómetros. Esto resulta interesante, ya que conocer el contenido en frecuencias de la señal permite detectar fallos, puesto que se dispone de las frecuencias características de fallo.

Para obtener el contenido en frecuencias de la señal, más conocido como espectro se pueden utilizar en función de la naturaleza de nuestra señal:

- Series de Fourier
- Transformada de Fourier
- Transformada de Fourier discreta

Las señales que se van a utilizar en este trabajo se han obtenido mediante sistemas de adquisición de datos. Esto significa que la señal no es continua sino discreta y para obtener el espectro de este tipo de señales se usa la Transformada de Fourier discreta.

$$X(k) = \sum_{n=0}^{N-1} x(n)e^{-j\frac{2\pi}{N}nk}$$

$$x(n) = \sum_{k=0}^{N-1} X(k)e^{j\frac{2\pi}{N}nk}$$

Siendo N el número de muestras.

La primera transformada permite pasar del dominio del tiempo al de la frecuencia y la segunda la contrario. En la práctica se utiliza la Transformada rápida de Fourier (FFT en inglés, Fast Fourier Transform), la cual permite obtener el espectro en un menor tiempo computacional.

### **Análisis de envolvente**

El análisis de envolvente es uno de los métodos más usados para detectar fallos de rodamientos en sus etapas de desarrollo iniciales. Se utiliza cuando la señal a analizar tiene forma de impulsos repetitivos y viene acompañada de ruido.

Al obtener la señal vibratoria de un rodamiento con un defecto se pueden visualizar ciertos picos, los cuales son registrados cuando partes del rodamiento chocan con el fallo, por ejemplo, si un rodamiento tiene un fallo en la pista externa, cada vez que un elemento rodante choque con este se produce un incremento de la amplitud de la señal. La frecuencia de esta señal es la conocida como portadora y vibra a la frecuencia natural del rodamiento, sin embargo, esa información no interesa a la hora de detectar fallos. Lo que se quiere conseguir es una señal de que tenga la frecuencia de los impactos que se generan en el fallo, para así visualizar en el espectro el armónico de esa frecuencia. A la señal que interesa obtener se la conoce como envolvente de la señal o señal modulada. Por lo tanto al aplicar el análisis de envolvente se consigue obtener esta señal.

Lo que realmente aporta información útil para detectar el fallo es el espectro de la envolvente de la señal. A el proceso de obtención del espectro de la envolvente se le conoce como demodulación. Este espectro es más útil que el de la señal original, ya que “la información sobre el fallo se obtiene a partir de la distancia entre impulsos y no a partir de las frecuencias excitadas” (Barszcz, 2019)

Mencionar, que este análisis sirve para fallos en sus primeras etapas de desarrollo, cuando aun se puede considerar que el fallo es local, es decir, que su tamaño no es mayor que el del rodamiento. Cuando el tamaño del fallo es más grande, la señal vibratoria se vuelve más compleja y no se obtienen buenos resultados.

El cálculo de la envolvente de la señal se caracteriza por dos aspectos, la técnica de demodulación y el rango de frecuencia de demodulación.

Las técnicas de demodulación más comunes son:

- Rectificación - Filtrado
- Aplicación de la transformada de Hilbert

El primer método es atractivo para implementación analógica, mientras que el segundo se aplica en el ámbito digital.

La forma más sencilla de obtener la envolvente de la señal es la siguiente:

- **Paso 1:** Aplicación de un filtro paso alto para descartar vibraciones de componentes de la máquina que tengan baja frecuencia, los cuales solo aportan ruido a la señal.
- **Paso 2:** Rectificación de la señal calculando su módulo
- **Paso 3:** Uso de un filtro paso bajo para descartar la parte de alta frecuencia de la señal.

A la hora de obtener la envolvente de la señal, puede ser interesante usar un ancho de banda concreto para realizar la demodulación. Si se elige un ancho de banda óptimo, se pueden obtener resultados mejores. Para la obtención de un ancho de banda óptimo existen varias técnicas, pero en este trabajo se presentará el uso del Kurtograma, ya que es la herramienta que se va utilizar.

Un Kurtograma es una representación de los valores de curtosis espectral para distintas frecuencias y longitudes de ventana.

La curtosis espectral está relacionada con la impulsividad de la señal. A mayor impulsividad mayor será la curtosis espectral. Gracias a esta, se puede conocer cuales son las bandas de frecuencia en las cuales la señal tiene mayor impulsividad, incluso cuando están ocultas por ruido.

Al realizar el kurtograma se obtienen, a parte de los valores de curtosis espectral en función de la frecuencia y la longitud de ventana, una frecuencia central y ancho de banda óptimos. Al filtrar la señal con un filtro de estas características, se obtiene la señal con el máximo valor de curtosis, que es lo que interesa para analizar el tipo de señal que genera cualquier fallo de los contemplados en este trabajo.

### 3.2. Aplicación de métodos de análisis de vibraciones


En este apartado se realizará un análisis de las señales vibratorias obtenidas de los rodamientos presentados en el punto 2.2. Al realizar el análisis se usarán los métodos tratados en el punto anterior, con el objetivo de obtener resultados que permitan distinguir cuando el rodamiento está en buen estado y cuando tiene algún fallo, intentando identificar de que fallo se trata. Para poder comparar las señales en función de si el rodamiento está en buen estado o tiene algún tipo de fallo, se han utilizado los datos recopilados con el motor girando a 1750 rpm, es decir, con una carga de 2 HP en el motor. Para el caso de fallo en pista interna, fallo en la bola y en la pista externa, el diámetro del defecto era de 0,007 pulgadas y concretamente para obtener la señal de la pista externa se han usado los datos obtenidos con el fallo situado en la posición relativa a la zona de carga centrada.

Las señales obtenidas para los distintos rodamientos son las siguientes, viéndose en el eje horizontal el tiempo en segundos y en el eje vertical la aceleración en fuerza g (g):

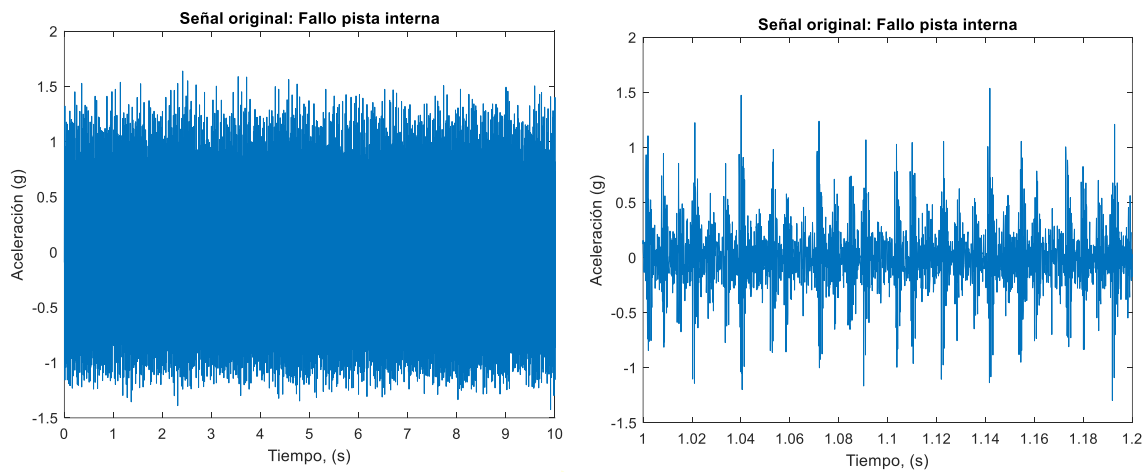


# Diseño de algoritmos de diagnóstico de fallos en rodamientos basados en métodos de machine learning aplicados al análisis de vibraciones

---



*Ilustración 4. Señal completa y ampliada del rodamiento 1 en buen estado*



*Ilustración 5. Señal completa y ampliada del rodamiento 1 con fallo en la pista interna*

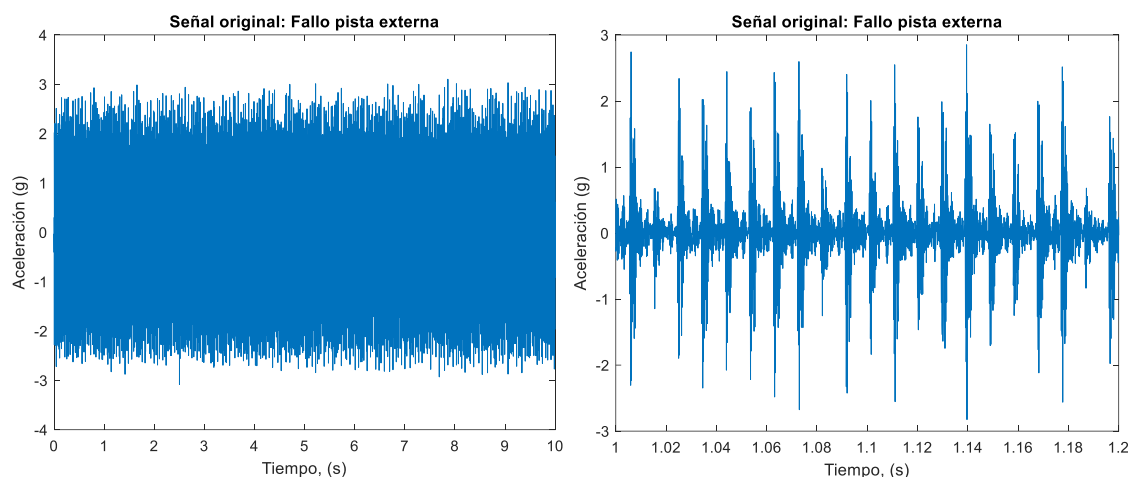


Ilustración 6. Señal completa y ampliada del rodamiento 1 con fallo en la pista externa

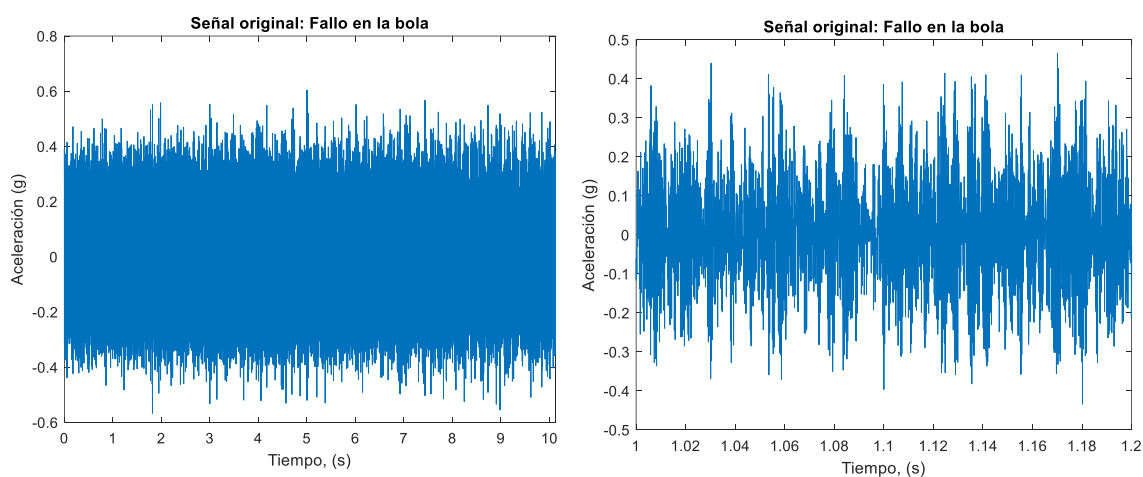


Ilustración 7. Señal completa y ampliada del rodamiento 1 con fallo en la bola

Al hacer zoom en las señales, se puede apreciar como la amplitud de la aceleración es mucho mayor en el caso de rodamientos con fallos respecto de la señal de un rodamiento sano, aunque cabe destacar que en el caso de fallo en la bola la amplitud de la aceleración es menor que para fallo en la pista interna y externa.

Pero tan solo con la señal original, es difícil diferenciar a simple vista entre un rodamiento con fallo en la pista interna o externa. Para ello se van a analizar las señales más profundamente.

Primero se visualizarán las señales en el dominio de la frecuencia. Para ello se utilizará el espectro de potencia, en el cual la amplitud de la señal es el cuadrado de la original.

# Diseño de algoritmos de diagnóstico de fallos en rodamientos basados en métodos de machine learning aplicados al análisis de vibraciones




Ilustración 8. Espectro de potencia de la señal del rodamiento 1 normal y ampliación de la región de bajas frecuencias

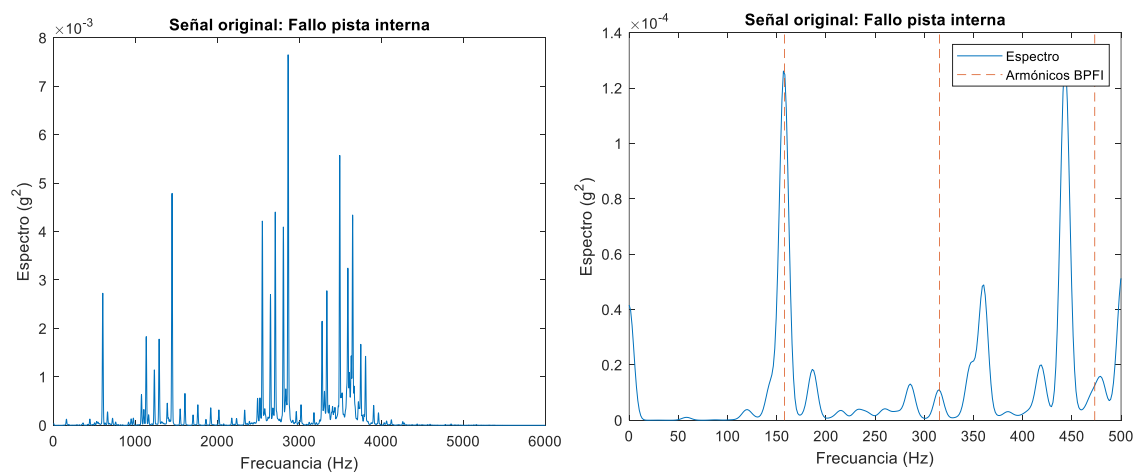


Ilustración 9. Espectro de potencia de la señal del rodamiento 1 con fallo en la pista interna y ampliación de la zona de bajas frecuencias

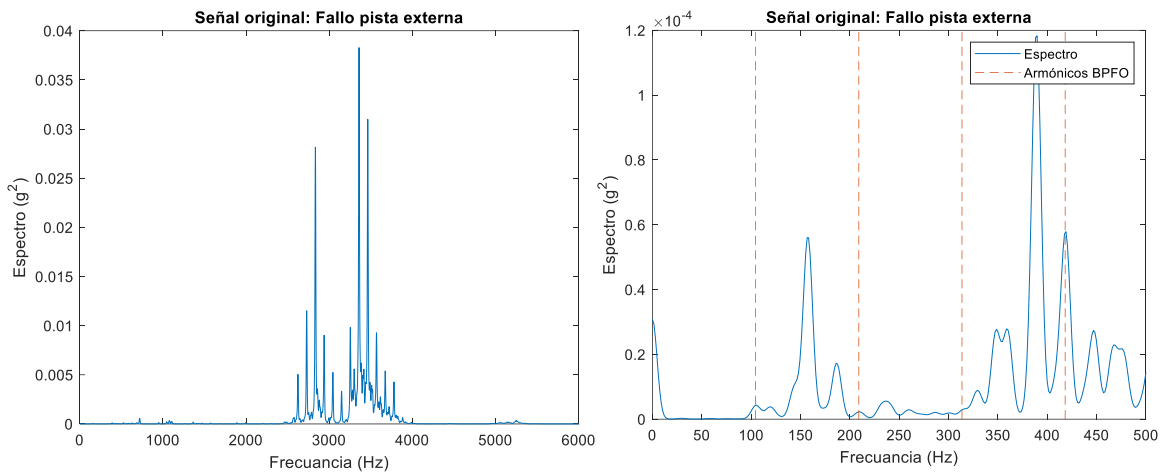


Ilustración 10. Espectro de potencia de la señal del rodamiento 1 con fallo en la pista externa y ampliación de la zona de bajas frecuencias

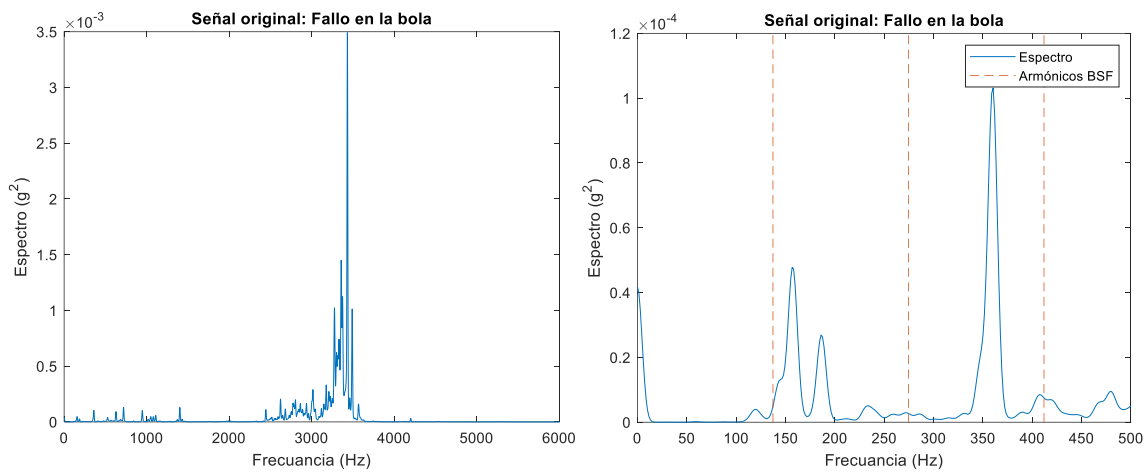


Ilustración 11. Espectro de potencia de la señal del rodamiento 1 con fallo en la bola y ampliación de la zona de bajas frecuencias

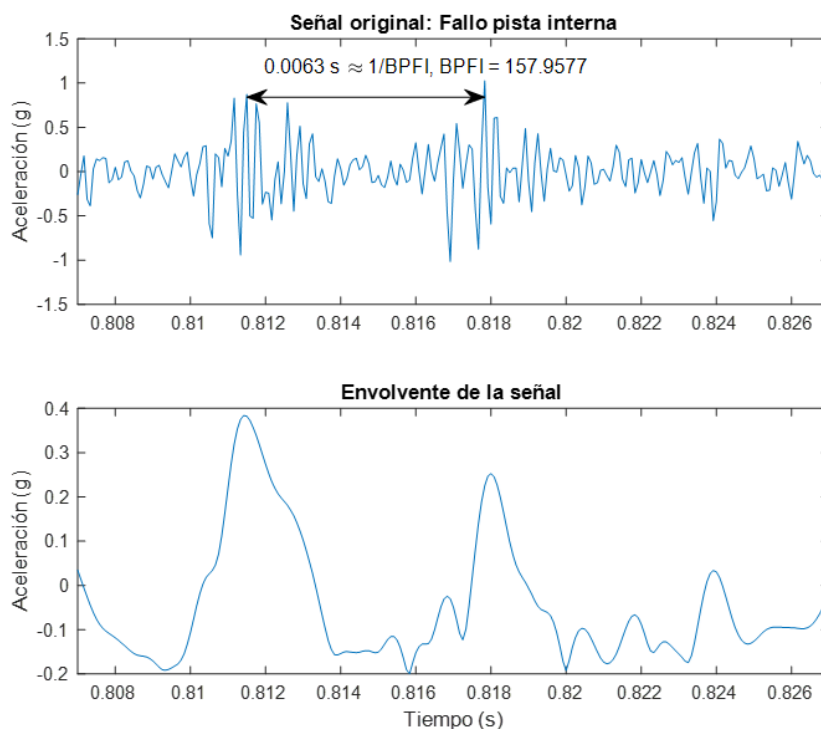
Se han representado dos gráficas para cada tipo de señal, ambas son las mismas solo que en las de la derecha se ha ampliado la zona de bajas frecuencias la cual contiene las frecuencias de defecto, ya que en la gráfica sin ampliar no se podían distinguir debido a la presencia de amplitudes mucho mayores en frecuencias más elevadas. Sin embargo, vemos que esta técnica solo funciona para el fallo en la pista interna, ya que vemos el armónico en esa frecuencia, pero para fallo en la pista externa y fallo en la bola no funciona bien, ya que los picos de mayor amplitud no están localizados en las frecuencias donde teóricamente deberían aparecer.

De todas formas, aunque haya funcionado para fallo en la pista interna, este método tiene un inconveniente y es que la amplitud de la señal en esas frecuencias es muy baja comparada con la de

frecuencias altas (2-4 kHz). La presencia de amplitudes tan altas a estas frecuencias probablemente se deba a que en ese rango se encuentra la frecuencia de resonancia del rodamiento.


El siguiente paso es calcular la envolvente de la señal para despreciar la parte de altas frecuencias correspondiente a la vibración natural del rodamiento. Como se ve en la siguiente ilustración, se ha representado la señal original en un tramo de tiempo muy pequeño (de 0,02 segundos) y debajo de esta su envolvente. Se puede apreciar como la envolvente no contiene las vibraciones de alta frecuencia que aparecen en cada impacto (puntos donde incrementa la amplitud de la señal).

En la primera gráfica se ha representado aproximadamente la distancia entre impactos en ese tramo. Entre impactos transcurren 0,0063 segundos, lo cual suponiendo que la señal se repite con ese periodo, corresponde a una frecuencia de 157,957 Hz, esta frecuencia es muy similar a la BPFI del rodamiento a 1750 rpm, que es 157,96 Hz.



*Ilustración 12. Señal vibratoria en el tiempo junto con la envolvente de la señal para fallo en la pista interna del rodamiento 1*

Una vez visto esto gráficamente, se calcula el espectro de la envolvente de la señal.

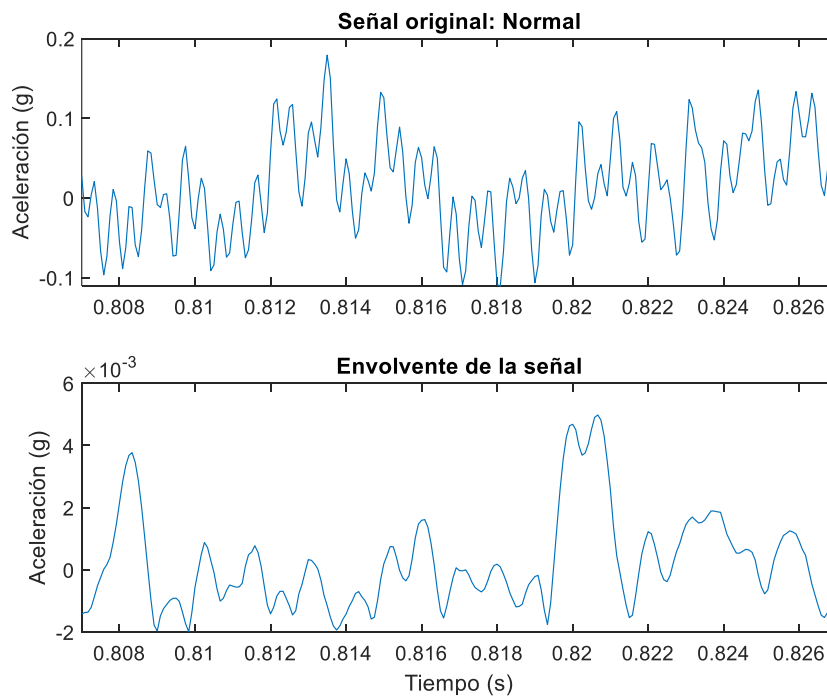


*Ilustración 13. Espectro de la envolvente de la señal del rodamiento 1 con fallo en la pista interna junto con los múltiplos de BPF1*

Se observa que las mayores amplitudes de la señal se encuentran en las frecuencias correspondientes a armónicos de BPF1, así se identifica claramente que la señal corresponde a un rodamiento con fallo en la pista interna.

Además, como es de esperar por lo comentado anteriormente, al visualizar el espectro de la envolvente a altas frecuencias, no aparecen las amplitudes que se veían el espectro de potencia de la señal original.

Se ha realizado el mismo análisis para la señal de rodamiento en buen estado.



*Ilustración 14. Señal vibratoria en el tiempo junto con la envolvente de la señal para el rodamiento 1 en buen estado*

En este caso, no se pueden diferenciar modulaciones de la señal tan significativas como en el caso anterior, lo cual es normal al no haber ningún fallo en el rodamiento. Cabe destacar que el valor máximo de la envolvente de la señal en este tramo es  $4,98 \times 10^{-3}$  aproximadamente, mucho menor que para fallo en la pista interna donde llega casi a 0,4 en el tramo representado.

Seguidamente, se calcula el espectro de la envolvente de la señal, donde se observa como no hay picos grandes ni en armónicos de BPFI, BPFO o BSF. Además, se aprecia como los picos máximos son mucho menores que en el caso del rodamiento con fallo en la pista interna.

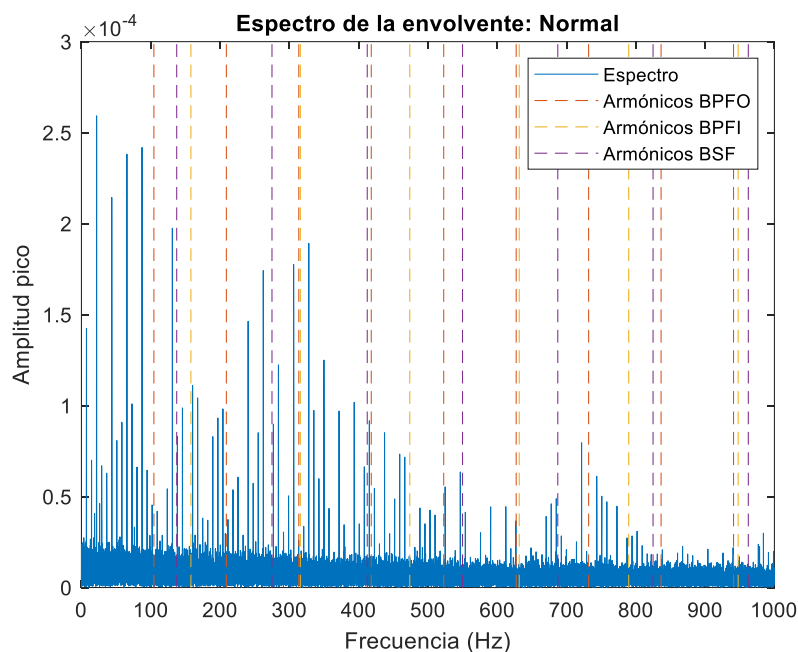


Ilustración 15. Espectro de la envoltura de la señal del rodamiento 1 en buen estado junto con los múltiplos de BPFI, BPFO y BSF

Se ha realizado el mismo análisis para la señal de fallo en la pista externa, dado que para este caso, la visualización de la señal en el dominio de la frecuencia tampoco aportaba información que permitiera diferenciar esa señal de una perteneciente a otro tipo de fallo.

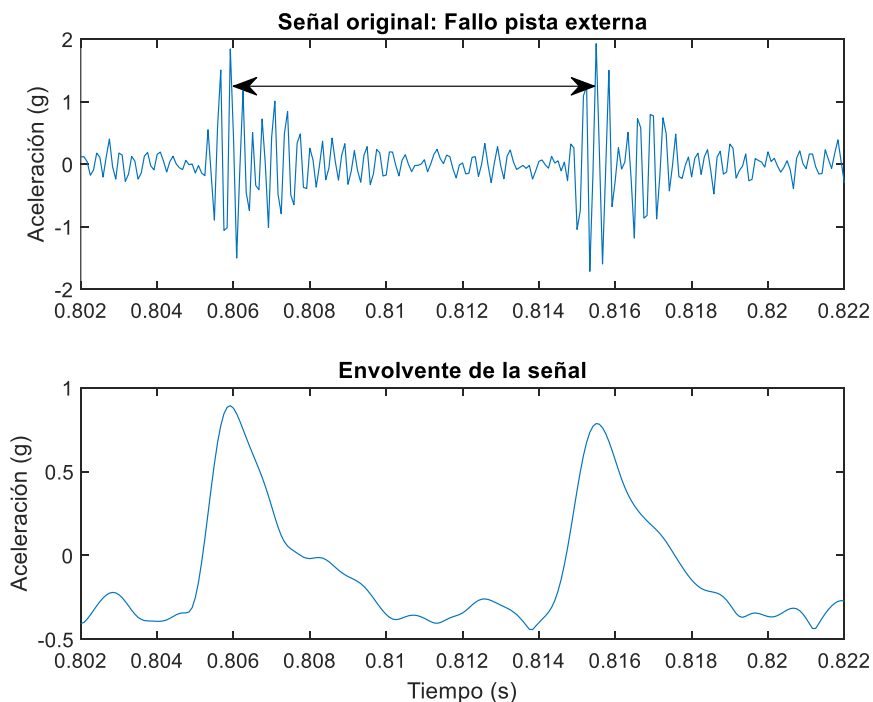


Ilustración 16. Señal vibratoria en el tiempo junto con la envoltura de la señal para fallo en la pista externa del rodamiento 1



Se puede observar una modulación de la aceleración entre 0,8059 y 0,8155 segundos, puntos donde la amplitud de la señal es mayor. Entre estos dos puntos hay 0,0096 segundos, lo cual corresponde a una frecuencia de  $1/0,0096=104,166$  Hz, la cual es muy similar a la frecuencia de BPFO para la velocidad a la que está girando el rodamiento (1750 rpm) es 104,55 Hz.




Ilustración 17. Espectro de la envoltura de la señal del rodamiento 1 con fallo en la pista externa junto con los múltiplos de BPFO

Por último, se realizará el mismo procedimiento para fallo en la bola.


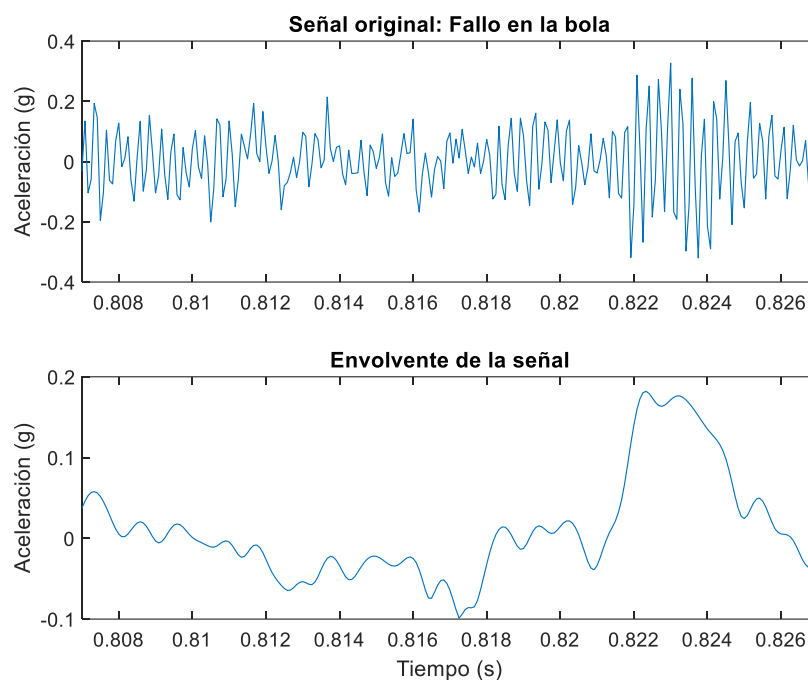


Ilustración 18. Señal vibratoria en el tiempo junto con la envoltura de la señal del rodamiento 1 para fallo de diámetro 0,007 pulgadas en la bola

Como se ha visto en anteriores gráficas la señal de fallo en la bola analizada tiene una amplitud mucho menor que las señales de los otros dos tipos de fallos contemplados, siendo más similar a una señal de rodamiento en buen estado. Por eso al visualizar la envolvente no se ven picos tan claros, siendo muy difícil diferenciar un rodamiento en buen estado de uno con fallo en la bola.

La señal de fallo en la bola utilizada para este análisis corresponde a un diámetro de fallo de 0,007 pulgadas (tabla con especificaciones de fallos). Se realizará este mismo análisis para un fallo de mayor diámetro, para poder determinar si está similitud entre ambas señales comentadas previamente, se debe a un tamaño de fallo demasiado pequeño como para ser detectado.

El tamaño del diámetro de fallo en la bola para este análisis es de 0,021 pulgadas.



*Ilustración 19. Señal vibratoria en el tiempo junto con la envolvente de la señal del rodamiento 1 para fallo de diámetro 0,021 pulgadas en la bola*

En este tramo, aunque hay una modulación de la amplitud en el segundo 0,822 aproximadamente, no se ve ningún patrón claro y al estudiar tramos distintos tampoco se consigue ver patrones de modulación de la señal que se repitan de forma significativa. Aun así, se ha calculado el espectro de la envolvente de la señal para confirmar si hay armónicos o no en BSF.




Ilustración 20. Espectro de la envolvente de la señal del rodamiento 1 con fallo de diámetro 0,007 pulgadas en la bola junto con los múltiplos de BSF

Se comprueba en este gráfico que los armónicos no coinciden con BSF, por lo tanto, este método no sirve para diferenciar si un rodamiento tiene fallo en la bola.

Se ha visto que el espectro de la envolvente ofrece más información que el espectro de la señal original, esto se debe a que en las señales vibratorias de rodamientos con algún fallo, el espacio entre los impactos no es constante, debido al deslizamiento y esto puede provocar variaciones del 1-2%. Esta variación entre impactos provoca que en el espectro de la señal original los armónicos de frecuencia no aparezcan en las frecuencias características de fallo que corresponden. Además, al hacer la demodulación de la señal, en el espectro de la envolvente no aparecen grandes amplitudes a altas frecuencias, como aparecían en el espectro de la señal original, que correspondían a la frecuencia natural del rodamiento. Esto se debe a que la envolvente no obtiene la parte de la señal de estas frecuencias, descartando la señal portadora y obteniendo la señal modulada.

A continuación, se realizará la demodulación de la señal con un ancho de banda personalizado. Para esto se utilizará el Kurtograma, técnica que ha sido descrita anteriormente. Se realizará para las mismas señales que se han presentado a lo largo de este apartado.

Este es el kurtograma y el espectro de la envolvente para el rodamiento en buen estado.




Ilustración 21. Kurtograma de la señal del rodamiento 1 en buen estado

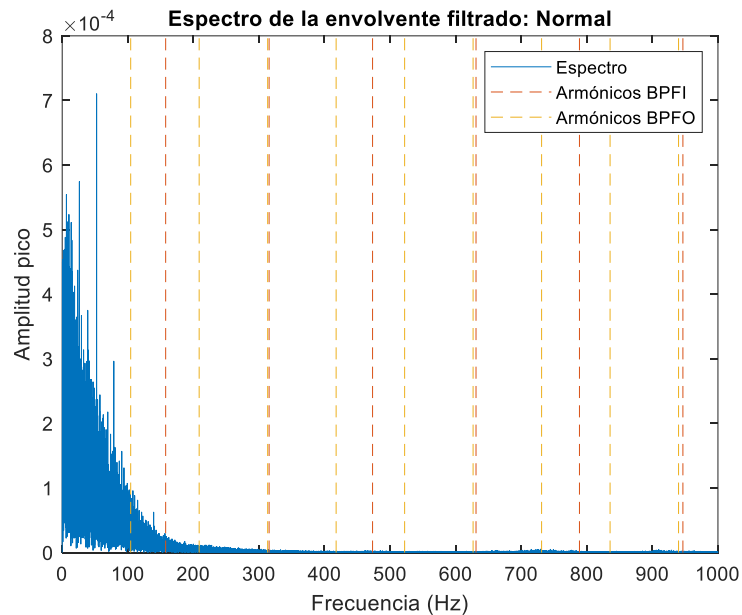


Ilustración 22. Espectro de la envolvente de la señal de rodamiento 1 en buen estado usando el ancho de banda óptimo según el kurtograma

En el espectro se aprecia que la amplitud aumenta en bajas frecuencias y en altas disminuye, de todas formas, en las frecuencias BPFO y BPFI los resultados son muy similares, por lo tanto, en este caso es indiferente usar un ancho de banda personalizado.

Ahora se analizará el fallo en la pista interna.

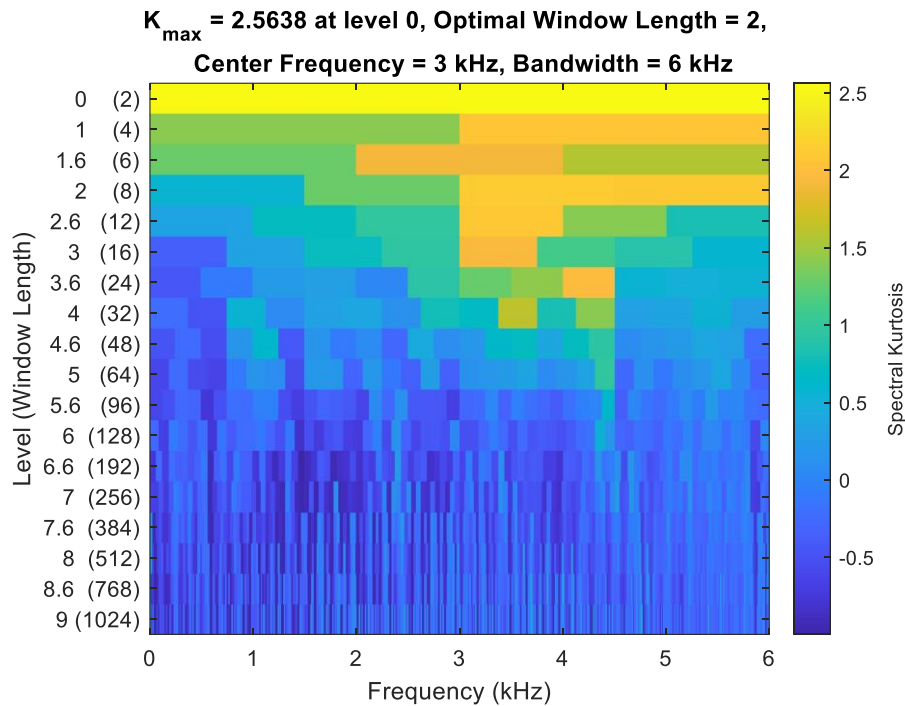


Ilustración 23. Kurtograma de la señal del rodamiento 1 con fallo en la pista interna




Ilustración 24. Espectro de la envolvente de la señal de rodamiento 1 con fallo en la pista interna usando el ancho de banda óptimo según el kurtograma

La amplitud del armónico en BPFÍ ha aumentado levemente, pasando de casi 0,14 a 0,18 aproximadamente, por lo tanto el uso del ancho de banda de acuerdo al Kurtograma es útil.

Seguidamente se analizará el fallo en la pista externa.




Ilustración 25. Kurtograma de la señal del rodamiento 1 con fallo en la pista externa




Ilustración 26. Espectro de la envolvente de la señal de rodamiento 1 con fallo en la pista exterior usando el ancho de banda óptimo según el kurtograma

En este caso la amplitud máxima ha aumentado levemente, pasando aproximadamente de 0,33 a 0,35.

Por último el fallo en la bola.




Ilustración 27. Kurtograma de la señal del rodamiento 1 con fallo en la bola

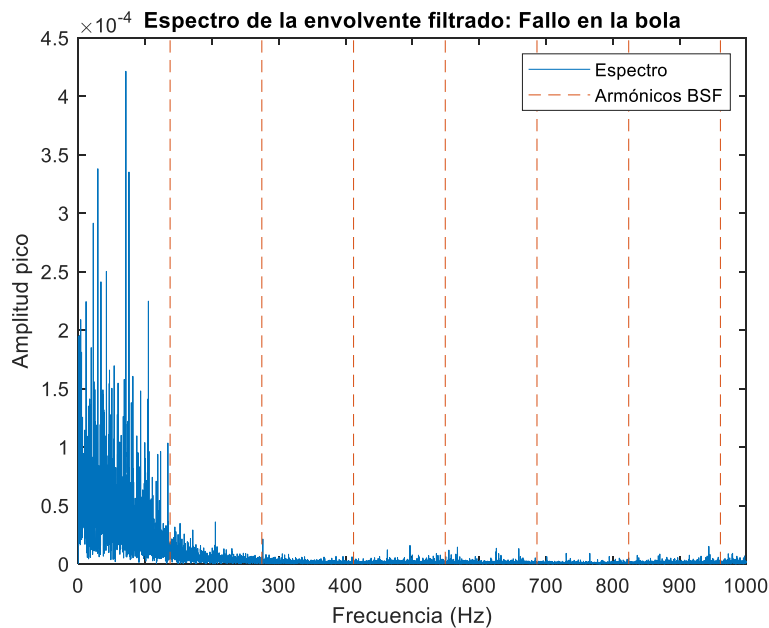


Ilustración 28. Espectro de la envolvente de la señal de rodamiento 1 con fallo en la bola usando el ancho de banda óptimo según el kurtograma

En este caso se ha realizado el kurtograma con el máximo ancho de ventana disponible, que en Matlab corresponde al nivel 10 (2048 ancho de ventana), pero no se han obtenido resultados mejores al usar el ancho de banda personalizado.

En base a los resultados obtenidos, parece que usar un ancho de banda personalizado puede ser útil ya que las amplitudes de la señal para rodamientos en buen estado no se modifican prácticamente y en los casos de fallo se obtiene una amplitud ligeramente superior que al no usarlo. Mencionar que para este rodamiento, en los casos de fallo en la pista externa de 0,007 pulgadas y velocidad de giro de 1772 rpm y de 0,021 pulgadas y velocidad de 1730 rpm, se obtuvieron mayores amplitudes sin el uso del ancho de banda sugerido por el kurtograma.

A continuación se realizará el mismo análisis del espectro de la envolvente para la señal del rodamiento del ventilador, la velocidad de giro del motor es la misma que en los casos anteriores, 1750 rpm (carga de 2 HP) y el tamaño de fallo también (0,007 pulgadas).



# Diseño de algoritmos de diagnóstico de fallos en rodamientos basados en métodos de machine learning aplicados al análisis de vibraciones

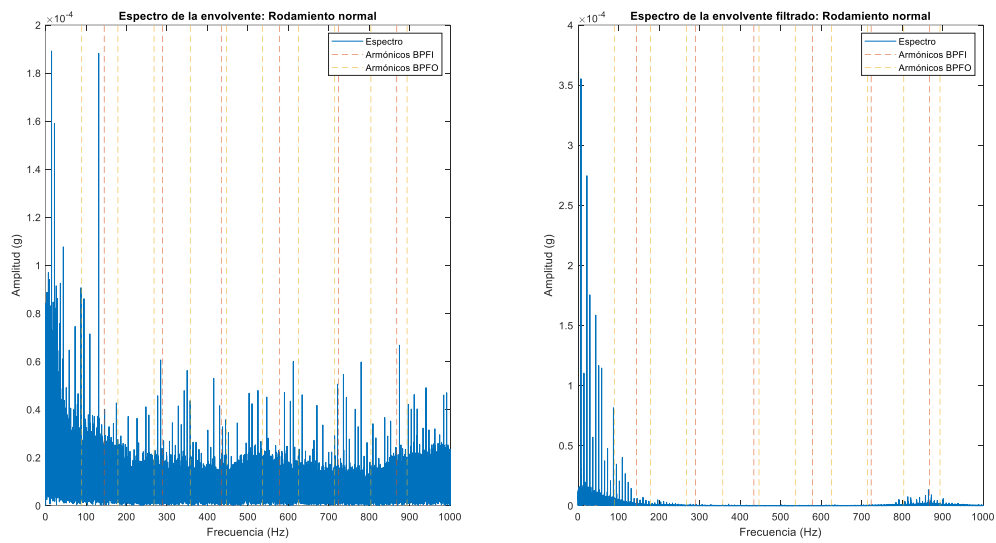


Ilustración 29. Espectro de la envolvente del rodamiento 2 en buen estado sin usar el ancho de banda sugerido por el kurtograma y usándolo

El espectro sin filtrar tiene mayor ruido que el filtrado, pero las amplitudes obtenidas son bastante similares, siendo ligeramente superiores las de la señal filtrada.

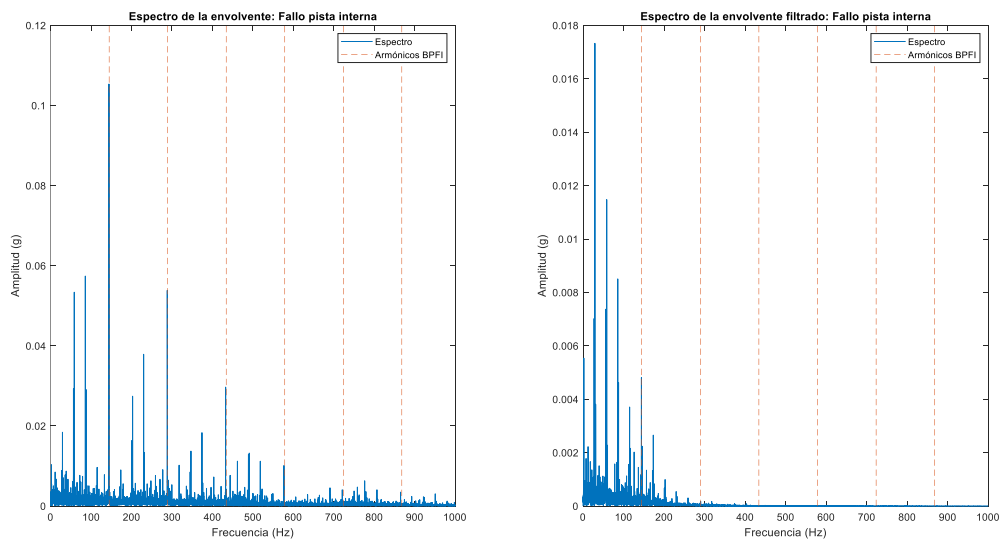


Ilustración 30. Espectro de la envolvente del rodamiento 2 con fallo en la pista interna sin usar el ancho de banda sugerido por el kurtograma y usándolo

En el caso de fallo en la pista interna al filtrar se reduce el ruido pero la amplitud pico de los armónicos es mucho menor y los picos de mayor amplitud no corresponden con las frecuencias de los armónicos BPFI, por lo tanto en este caso el ancho de banda obtenido mediante el kurtograma no es efectivo. Este es el kurtograma obtenido.




Ilustración 31. Kurtograma obtenido para fallo en la pista interna del rodamiento 2

Puede que el kurtograma no funcione bien en este caso debido a que es un método que tiene alta sensibilidad a componentes aleatorios extraños los cuales pueden ser los causantes del resultado obtenido.

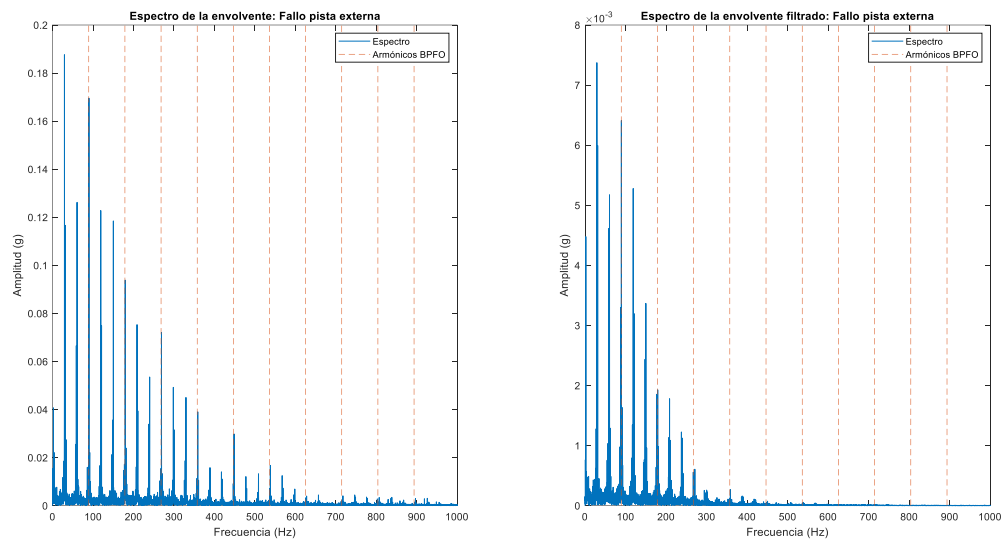


Ilustración 32. Espectro de la envolvente de la señal de fallo en la pista externa del rodamiento 2 sin usar el ancho de banda sugerido por el kurtograma y usándolo

Para el fallo en la pista externa ocurre algo similar al fallo en la pista interna. En este caso el Kurtograma indica que la frecuencia central y ancho de banda para la demodulación son 4,6875 kHz y 0,375kHz respectivamente.

Por lo tanto, para el rodamiento del ventilador no se usará un ancho de banda personalizado ya que sin su uso se obtienen mejores resultados que al usar el sugerido por el kurtograma.

En resumen, mediante el espectro de la envolvente de las señales ha sido posible diferenciar entre señales de rodamientos en buen estado, con fallo en la pista interna y fallo en la pista externa, sin embargo, para fallo en la bola no ha sido útil, ya que los armónicos no coinciden con BSF. Después se ha visto que el uso de un ancho de banda personalizado para la demodulación consigue mejores resultados para el rodamiento del eje del motor mientras que para el rodamiento del ventilador empeora los resultados.

#### 4. Obtención de características

La obtención de características es una de las partes más importantes del machine learning. Mediante este proceso se consigue transformar datos brutos, a información que el algoritmo puede utilizar.

Una vez se han analizado las señales se puede llegar a la conclusión de que a priori un buen indicador para detectar el estado del rodamiento es la amplitud del espectro de la envolvente de la señal en las frecuencias de defecto (BPFO y BPFI). Se puede esperar que para un rodamiento con fallo en la pista interna, la amplitud del espectro de la envolvente de la señal sea mucho mayor en BPFI que en BPFO y para fallo en la pista externa sería lo contrario y por último si el rodamiento está en perfecto estado las amplitudes tanto en BPFI como BPFO serán de magnitud similar pero mucho más reducidas que en el caso de fallo.

Por lo tanto, como primer enfoque a la hora de obtener las características necesarias para poder entrenar y validar los distintos algoritmos de Machine Learning, se calcularán las amplitudes del espectro de la envolvente de la señal en BPFI y BPFO para cada uno de los sets de datos disponibles.

Los resultados obtenidos se han almacenado en una tabla de Matlab, donde cada fila es un archivo de datos distinto y en las columnas se han recogido: la amplitud en BPFI, amplitud en BPFO, etiqueta del estado del rodamiento, nombre del archivo de datos. La tabla obtenida es la siguiente:

	1	2	3	4
	BPFIAmplitude	BPFOAmplitude	etiqueta	archivo
1	0.1900	0.0013	'Pista interna'	'IR007_1'
2	0.1864	0.0013	'Pista interna'	'IR007_2'
3	0.1550	0.0034	'Pista interna'	'IR007_3'
4	0.2201	0.0097	'Pista interna'	'IR021_1'
5	0.2856	0.0122	'Pista interna'	'IR021_2'
6	0.2620	0.0130	'Pista interna'	'IR021_3'
7	2.5954e-06	7.2277e-06	'Normal'	'Normal_0'
8	1.7379e-06	2.7585e-06	'Normal'	'Normal_1'
9	1.6922e-05	6.7365e-05	'Normal'	'Normal_2'
10	6.7861e-05	2.7525e-04	'Normal'	'Normal_3'
11	0.0045	0.5618	'Pista externa'	'OR007@6_0'
12	0.0106	0.3587	'Pista externa'	'OR007@6_2'
13	0.0076	0.4738	'Pista externa'	'OR007@6_3'
14	0.0093	0.3887	'Pista externa'	'OR021@6_0'
15	0.0140	0.4078	'Pista externa'	'OR021@6_1'
16	0.0175	0.4040	'Pista externa'	'OR021@6_2'
17	0.1223	0.0134	'Pista interna'	'IR007_0FE'
18	0.1158	0.0023	'Pista interna'	'IR007_1FE'
19	0.1054	0.0051	'Pista interna'	'IR007_2FE'
20	0.0765	0.0036	'Pista interna'	'IR007_3FE'
21	0.1065	0.0049	'Pista interna'	'IR021_0FE'
22	0.1013	0.0102	'Pista interna'	'IR021_1FE'
23	0.1420	0.0081	'Pista interna'	'IR021_2FE'
24	0.1023	0.0080	'Pista interna'	'IR021_3FE'

Ilustración 33. Imagen de parte de la tabla obtenida con las características y una etiqueta indicando el estado del rodamiento para cada archivo de datos

La tabla completa tiene 37 filas, que se corresponden con puntos, ya que al estar determinados por dos variables pueden ser representados en el plano. La app de Matlab Classification Learner, mediante la cual se entrenarán y exportarán los algoritmos más tarde, permite representar los puntos en el plano, visualizando la característica o predictor deseado en el eje horizontal y lo mismo en el vertical, pudiendo visualizar distintas combinaciones de predictores. Como en este trabajo se usan solo dos predictores, no hay más que una combinación de estos a la hora de visualizar los datos. A los datos de rodamientos en buen estado se les ha etiquetado como "Normal", a los que tienen un

fallo en la pista interna como “Pista interna” y a los que tienen fallo en la pista externa “Pista externa”.

Esta es la disposición de las características extraídas:




Ilustración 34. Características obtenidas representadas en el plano

## 5. Entrenamiento y validación de algoritmos

Una vez ya se han obtenido las características y datos necesarios, es el momento de entrenar los distintos algoritmos con estos datos. La idea es dividir el set de datos para utilizar una parte de estos para entrenar los algoritmos y la otra parte para validarlos, ya que de esta manera se evita el overfitting o sobreajuste.

En machine learning, el sobreajuste es la adaptación excesiva de un algoritmo al conjunto de datos de entrenamiento. Un algoritmo con sobreajuste funciona correctamente con los datos de entrenamiento, pero con datos distintos tiene una precisión menor, ya que al adaptarse demasiado a características específicas de los datos de entrenamiento, no predice correctamente para datos distintos. En definitiva, el modelo no generaliza como debería. (Wikipedia, s.f.)

Por lo tanto de los 37 datos recopilados, 19 se han usado para entrenar los algoritmos y los restantes se usarán posteriormente en el proceso de validación.

Para proteger a los algoritmos del sobreajuste y obtener precisiones realistas, la app utiliza “Cross-Validation” o validación cruzada.

Esta técnica divide los datos en un número de particiones determinado, que en este caso es 5, y para cada partición entrena un algoritmo usando los datos fuera de la partición y calcula la precisión “inicial” de este con los datos de la partición. La precisión final obtenida es la media de precisión para todas las particiones.

Esta técnica es la recomendada para bancos de datos pequeños. Cabe destacar, que aunque al obtener la precisión de cada algoritmo en el entrenamiento no se use el banco de datos completo, el algoritmo que la app permite extraer se obtiene usando todos los datos de entrenamiento, por lo tanto sigue siendo necesario dividir el banco de datos en dos partes para realizar la validación posteriormente.

Para analizar la clasificación de los algoritmos se van a utilizar matrices de confusión. Las matrices de confusión son herramientas muy útiles en el aprendizaje supervisado, ya que permiten detectar si el algoritmo se está confundiendo entre ciertas clases al predecir. En las columnas de la matriz se indican las predicciones para cada clase y en las filas el valor real. Por lo tanto, si en la matriz solo aparecen números en la diagonal, el algoritmo clasifica todos los datos correctamente, sin embargo, los números que aparezcan fuera de las diagonales son datos clasificados incorrectamente.

### 5.1. Resultados del entrenamiento

Los distintos tipos de algoritmos que ofrece la herramienta se presentaron en la introducción. Cada familia de algoritmos tiene variantes del algoritmo, en las siguientes tablas se presentarán las precisiones obtenidas al entrenar los datos para cada variante de los distintos algoritmos, junto con las matrices de confusión de los algoritmos que no hayan obtenido una precisión del 100%.

- Árboles de decisión:

Algoritmo	Precisión
Árbol fino	78,9%
Árbol medio	78,9%
Árbol grueso	78,9%

Tabla 4. Precisiones de los árboles de decisión entrenados




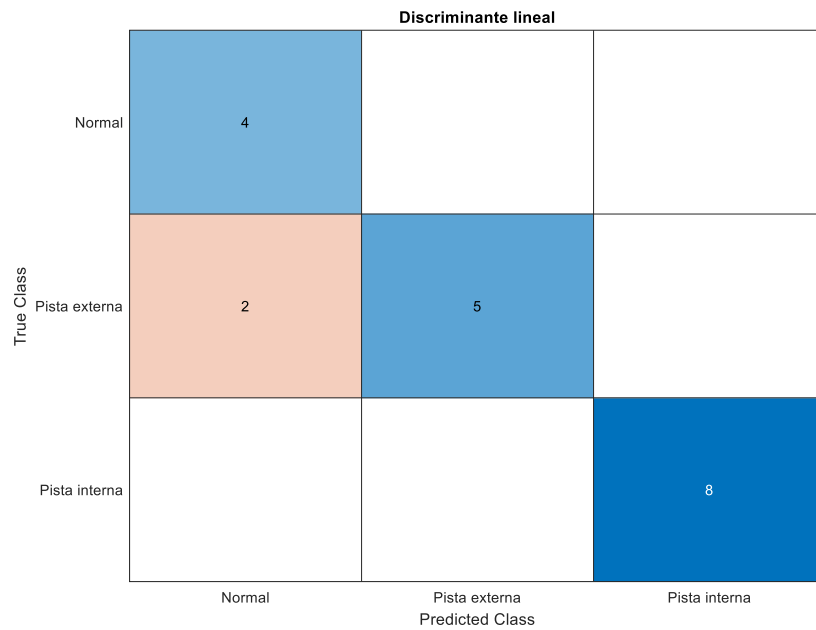
Ilustración 35. Matriz de confusión de los árboles de decisión entrenados

- Análisis discriminante:


Algoritmo	Precisión
Discriminante lineal	89,5%
Discriminante cuadrático	89,5%

Tabla 5. Precisiones de los algoritmos de análisis discriminante entrenados





*Ilustración 36. Matriz de confusión del discriminante lineal entrenado*



*Ilustración 37. Matriz de confusión del discriminante cuadrático entrenado*

- Naïve Bayes:

Algoritmo	Precisión
Naïve Bayes Gaussiano	100%
Naïve Bayes de Kernel	89,5%

Tabla 6. Precisiones de los algoritmos de Naïve Bayes entrenados




Ilustración 38. Matriz de confusión del algoritmo Naïve Bayes de Kernel entrenado


- Máquinas de vector soporte (SVM):

Algoritmo	Precisión
SVM lineal	89,5%
SVM cuadrático	100%
SVM cúbico	100%
SVM Gaussiano fino	94,7%
SVM Gaussiano medio	100%
SVM Gaussiano grueso	78,9%


Tabla 7. Precisiones de los algoritmos SVM entrenados

# Diseño de algoritmos de diagnóstico de fallos en rodamientos basados en métodos de machine learning aplicados al análisis de vibraciones

---



*Ilustración 39. Matriz de confusión del SVM lineal entrenado*



*Ilustración 40. Matriz de confusión del SVM Gaussiano fino entrenado*




Ilustración 41. Matriz de confusión del SVM Gaussiano grueso entrenado

- K Vecinos más cercanos (KNN):

Algoritmo	Precisión
KNN fino	100%
KNN medio	73,7%
KNN grueso	31,6%
KNN coseno	78,9%
KNN cúbico	73,7%
KNN ponderado	100%

Tabla 8. Precisiones de los algoritmos KNN entrenados

**KNN medio**


	Normal			
True Class	Normal			4
	Pista externa	1	6	
	Pista interna			8
		Normal	Pista externa	Pista interna
		Predicted Class		

Ilustración 42. Matriz de confusión del KNN medio entrenado


**KNN grueso**

	Normal			
True Class	Normal		2	2
	Pista externa		2	5
	Pista interna		4	4
		Normal	Pista externa	Pista interna
		Predicted Class		

Ilustración 43. Matriz de confusión del KNN grueso entrenado



*Ilustración 44. Matriz de confusión del KNN cúbico entrenado*



*Ilustración 45. Matriz de confusión del KNN coseno entrenado*

5.2. Resultados de la validación

- Árboles de decisión:

Algoritmo	Precisión
Árbol fino	100%
Árbol medio	100%
Árbol grueso	100%

Tabla 9. Precisiones de los árboles de decisión en la validación

- Análisis discriminante:

Algoritmo	Precisión
Discriminante lineal	100%
Discriminante cuadrático	94,44%

Tabla 10. Precisiones de los algoritmos de análisis discriminante en la validación

**Discriminante cuadrático**

Clase verdadera	Normal	3		1
	Pista externa		6	
	Pista interna			8
		Normal	Pista externa	Pista interna

Clase predecida

Ilustración 46. Matriz de confusión del discriminante cuadrático validado

- Naïve Bayes:

Algoritmo	Precisión
Naïve Bayes Gaussiano	94,44%
Naïve Bayes de Kernel	94,44%

Tabla 11. Precisiones de los algoritmos de Naïve Bayes en la validación

		Naïve Bayes		
		Normal	Pista externa	Pista interna
Clase verdadera	Normal	3		1
	Pista externa		6	
	Pista interna			8
		Normal	Pista externa	Pista interna
		Clase predecida		

Ilustración 47. Matriz de confusión de los algoritmos Naïve Bayes validados

Ambos algoritmos Naïve Bayes tienen la misma matriz de confusión.

- Máquinas de vector soporte (SVM):

Algoritmo	Precisión
SVM lineal	100%
SVM cuadrático	100%
SVM cúbico	100%
SVM Gaussiano fino	100%
SVM Gaussiano medio	100%
SVM Gaussiano grueso	77,78%

Tabla 12. Precisiones de los algoritmos SVM en la validación



**SVM Gaussiano grueso**

Clase verdadera	Normal		4	
	Pista externa	6		
	Pista interna		8	
		Normal	Pista externa	Pista interna
		Clase predecida		

Ilustración 48. Matriz de confusión del SVM Gaussiano grueso validado

- K Vecinos más cercanos (KNN):

Algoritmo	Precisión
KNN fino	100%
KNN medio	100%
KNN grueso	44,44%
KNN coseno	100%
KNN cúbico	100%
KNN ponderado	100%

Tabla 13. Precisiones de los algoritmos KNN en la validación

**KNN grueso**

Clase verdadera	Normal		4	
	Pista externa		6	
	Pista interna		8	
		Normal	Pista externa	Pista interna
		Clase predecida		

Ilustración 49. Matriz de confusión del KNN grueso validado

### 5.3. Análisis de resultados

Una vez se han visto todos los resultados, se razonará porque ciertos algoritmos han tenido mayor precisión que otros.

Se ha visto que los árboles de decisión, aunque en entrenamiento no han obtenido una precisión muy elevada, han clasificado los datos perfectamente en validación. Esto se debe a la forma que tiene Classification Learner de calcular la precisión al usar la validación cruzada. A continuación se visualizará el árbol obtenido, ya que las tres variantes del algoritmo han obtenido el mismo resultado.

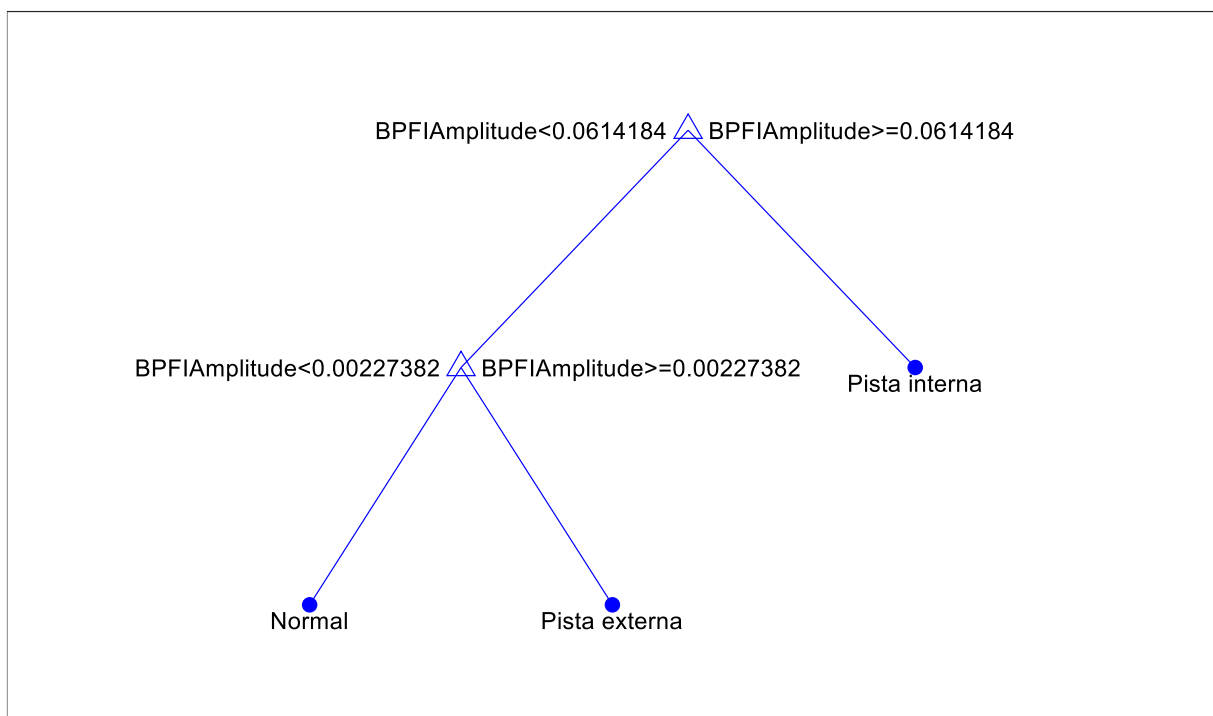


Ilustración 50. Árbol de decisión obtenido

Se puede notar que el árbol obtenido es bastante simple, siendo poco profundo y que tan solo utiliza el predictor AmplitudBPF. Se sabe que este tipo de algoritmos permite relaciones no lineales entre las variables explicativas (predictores) y la variable dependiente y que se ven muy influenciados por valores atípicos o que sobresalen en relación con el resto de datos usados para entrenar. Puesto que la distribución de los datos de entrenamiento es bastante homogénea, tiene sentido que se haya obtenido una buena precisión.

El siguiente algoritmo a analizar es el análisis discriminante, este algoritmo suele funcionar bien para sets de datos grandes, lo cual no es el caso del set utilizado en este trabajo. El análisis discriminante

asume que las diferentes clases generan datos basándose en distribuciones de Gauss distintas, por lo tanto al entrenarlo la función de ajuste estima los parámetros de una distribución de Gauss para cada clase.

Por lo tanto la alta precisión obtenida puede ser consecuencia de que los datos sigan una distribución similar a la de Gauss para cada clase, ajustándose más a un modelo lineal que a uno cuadrático.

Seguidamente se comentarán los clasificadores de Naive Bayes, los cuales han obtenido una buena precisión. Estos algoritmos se basan en el teorema de Bayes, el cual asume que dada una clase, los predictores son condicionalmente independientes, sin embargo, parece que el algoritmo funciona bien aunque no se cumpla esa independencia.

El algoritmo utiliza el teorema de Bayes para decidir a que clase pertenece cada dato que analiza, calculando las probabilidades que necesita a partir de los datos de entrenamiento. El algoritmo que utiliza la distribución Gaussiana ha tenido un 100% de precisión en entrenamiento mientras que el de Kernel ha obtenido un 89,5%, pero al validarlos ambos han clasificado los datos con un 94,4%, clasificando un rodamiento normal como fallo en la pista interna. Esto puede deberse a que los predictores no siguen una distribución normal ni de kernel para la clase normal, aunque también puede deberse a que el número de observaciones de rodamiento normal en entrenamiento ha sido más reducido que para el resto de clases.

Ahora se analizarán los resultados obtenidos para los algoritmos de Máquinas de vector soporte o SVM. Se han obtenido mejores resultados en test que en entrenamiento, debido a la validación cruzada. Al validar, todas las variantes han obtenido la máxima precisión excepto el modelo Gaussiano grueso. Para poder entender porque los algoritmos SVM han clasificado correctamente los datos, se va a explicar gráficamente su funcionamiento.

En la siguiente imagen se puede ver gráficamente el funcionamiento del SVM, siendo + un tipo de datos y – otro, este algoritmo trata de buscar el mejor hiperplano (Separating hyperplane en la imagen) que separa a los vectores soporte (Support vector), que son los datos más cercanos al hiperplano. El mejor hiperplano es aquel que tiene el mayor margen entre las dos clases, siendo el margen la anchura máxima entre las paralelas al hiperplano que no tiene puntos interiores.




Ilustración 51. Representación gráfica del algoritmo SVM. Fuente: (The MathWorks)

En este ejemplo el algoritmo trabaja con dos clases, pero en este trabajo el algoritmo maneja tres clases, por lo tanto, el problema pasa a ser multiclase. En estos casos el algoritmo SVM divide los problemas multiclase en problemas de clasificación binarios, de esta forma se dividen los datos distinguiendo entre una clase y el resto de clases agrupadas, haciendo esto para todas las clases presentes. Esto se conoce como uno frente a todos (One vs. All). A continuación, se representará gráficamente el concepto uno frente a todos para cada clase, usando los datos de entrenamiento.

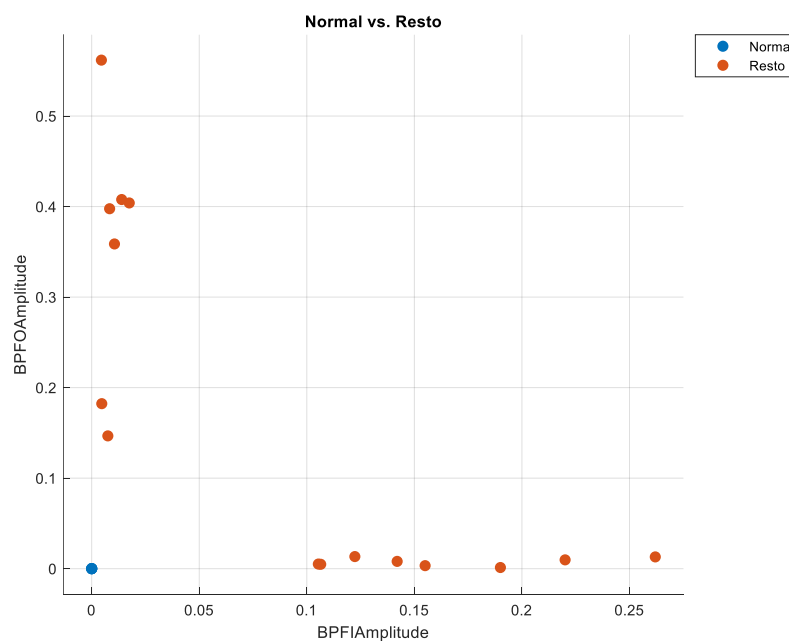


Ilustración 52. Representación de datos de la clase normal frente al resto




Ilustración 53. Representación de datos de la clase pista interna frente al resto

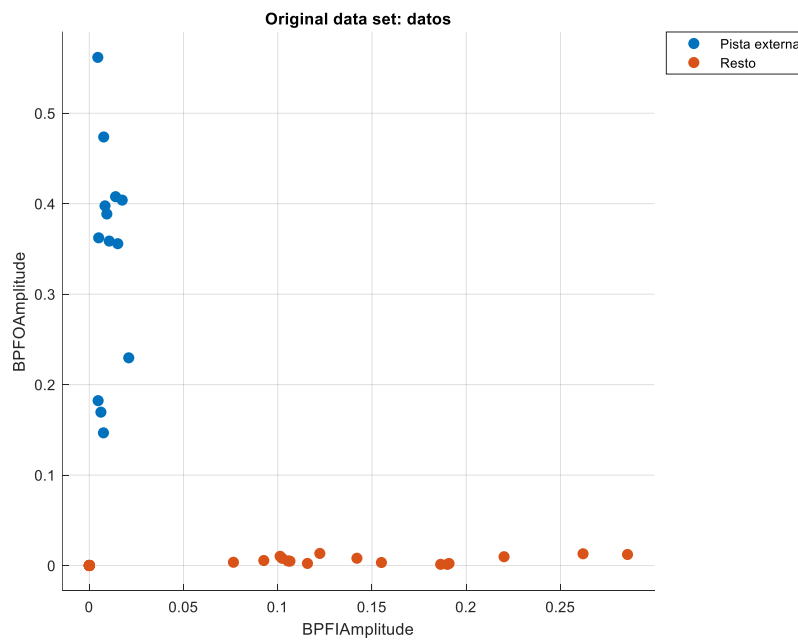


Ilustración 54. Representación de datos de la clase pista externa frente al resto

Puesto que los datos de distintas clases están claramente separados unos de otros, no es de extrañar que se haya obtenido una alta precisión en los algoritmos SVM, incluso en su forma lineal, que es la más simple.

El único SVM que no ha clasificado correctamente los datos es el Gaussiano grueso, el cual ha utilizado una función de kernel Gaussiana y una escala de kernel de 5,7. Tanto el Gaussiano fino como medio han usado la misma función de kernel pero con escalas de kernel menores, siendo 0,35 para el fino y 1,4 para el medio, por lo tanto se puede deducir que la falta de precisión es debido a la elevada escala de kernel.

Por último, se analizará el algoritmo k vecinos más cercanos o próximos (KNN), se sabe que este algoritmo clasifica nuevos datos basándose en el tipo de datos más cercanos en el espacio al nuevo dato. En entrenamiento las máximas precisiones se han obtenido para el KNN fino y el KNN ponderado, mientras que al validar todos han obtenido la máxima precisión excepto el KNN grueso. En la siguiente tabla se presentan los parámetros de cada KNN.

Algoritmo	Número de vecinos (k)	Medida de distancia
KNN fino	1	Euclídea
KNN medio	10	Euclídea
KNN grueso	100	Euclídea
KNN coseno	10	Coseno
KNN cúbico	10	Minkowski
KNN ponderado	10	Euclídea

Tabla 14. Número de vecinos y medida de distancia para los distintos KNN

Respecto a los resultados del entrenamiento, se ve que al utilizar la distancia euclídea el mejor resultado se ha obtenido al usar un número de vecinos reducido, esto puede deberse a que el número de datos es demasiado pequeño como para usar 10 vecinos. El uso de la distancia similitud coseno ha mejorado levemente la precisión, ya que para el mismo número de vecinos (10) obtiene mayor precisión que la distancia euclídea, pero no se puede llegar a una conclusión inequívoca de que funcionará mejor que la distancia euclídea, por su parte el uso distancia de Minkowski ofrece una precisión prácticamente igual que la euclídea (para 10 vecinos). Por último, el KNN ponderado obtiene la misma precisión que el KNN fino, pero utilizando 10 vecinos, la diferencia entre estos dos KNNs reside en la ponderación de la distancia a los vecinos. Todos los KNN entrenados excepto el ponderado dan los mismos pesos a cada distancia calculada, mientras que el ponderado da pesos distintos a la contribución de cada vecino. Este KNN pondera las contribuciones de cada vecino de acuerdo al cuadrado inverso de sus distancias. Al dar más peso a los vecinos más cercanos en relación con los más lejanos, se obtiene una alta precisión aun considerando un número de vecinos que ha disminuido la precisión para KNNs que no han utilizado esta ponderación.

En la validación se observa que todos los algoritmos funcionan bien, excepto el KNN que usa 100 vecinos, lo cual se debe a que el número de datos es demasiado reducido como para usar un número de vecinos tan elevado. Por lo tanto, se puede concluir que el número de vecinos óptimo esta entre 1 y 10 y que la distancia euclídea y la similitud coseno son las medidas de distancia que mayor precisión ofrecen.

## 6. Conclusiones

La realización de este trabajo se puede dividir en dos partes principales: el análisis de vibraciones y Machine learning.

Dentro del análisis de vibraciones, se puede concluir que el análisis de envolvente es un método válido para la detección de fallos en rodamientos. En concreto, el espectro de la envolvente de la señal es la herramienta que ha ofrecido mejores resultados para caracterizar los fallos, ofreciendo más información que el espectro de la señal original. Además, se ha visto que el uso de un ancho de banda óptimo, calculado mediante el kurtograma, para obtener la envolvente de la señal, en ciertas ocasiones ha mejorado los resultados, pero en otras los ha empeorado, obteniendo en reglas generales mejores resultados al usarlo en el rodamiento del eje que transmite par, que en el rodamiento del ventilador. En la siguiente tabla se puede ver lo comentado.

Archivo	Sin uso de ancho de banda óptimo	Uso de ancho de banda óptimo
<b>IR007_2 (DE)</b>	Amplitud en BPFI=0,1367 Amplitud en BPFO=0,0017	Amplitud en BPFI=0,1864 Amplitud en BPFO=0,0013
<b>IR007_2 (FE)</b>	Amplitud en BPFI=0,1054 Amplitud en BPFO=0,0051	Amplitud en BPFI=0,0048 Amplitud en BPFO=9,9649e-4
<b>OR007@6_2 (DE)</b>	Amplitud en BPFI=0,0106 Amplitud en BPFO=0,3373	Amplitud en BPFI=0,0106 Amplitud en BPFO=0,3587
<b>OR007@6_2 (FE)</b>	Amplitud en BPFI=0,0062 Amplitud en BPFO=0,1696	Amplitud en BPFI=7,2005e-4 Amplitud en BPFO=0,0064

*Tabla 15. Amplitudes de armónicos de frecuencia BPFI y BPFO para fallos en la pista interna y externa para el rodamiento del eje que transmite par (DE) y para el rodamiento del ventilador (FE) cuando se ha calculado la envolvente de la señal usando ancho de banda óptimo y sin hacer uso de este*

El único caso para el cual no ha funcionado el análisis de envolvente ha sido el fallo en la bola, ya que no se han obtenido armónicos de frecuencia igual a la de fallo en la bola.

Pasando a la parte de Machine learning, se ha visto que la aplicación de los distintos algoritmos al diagnóstico de fallos, es una herramienta muy potente que permite automatizar el proceso de diagnóstico de estos.

El primer paso a la hora de entrenar algoritmos de Machine learning de aprendizaje supervisado, como es el caso de los algoritmos de este trabajo, es obtener las características o predictores que utilizará el algoritmo para clasificar. Vistos los resultados del análisis de vibraciones, se concluyó que la amplitud del espectro de la envolvente de la señal en las frecuencias de fallo de pista interna y pista externa podrían ser buenos predictores, ya que para fallo cada fallo se obtenía una gran amplitud en la frecuencia correspondiente a ese tipo de fallo, en comparación con la amplitud en la otra frecuencia de fallo que no era la que estaba sufriendo el rodamiento.

Posteriormente al entrenar los algoritmos se confirmó la hipótesis supuesta en un inicio respecto a los predictores. Los algoritmos que mejor rendimiento han ofrecido en este trabajo, entendiendo como mejor rendimiento que hayan obtenido 100% de precisión en entrenamiento y en validación,

son: los SVM, más concretamente en sus variantes cuadrática, cúbica y Gaussiana media y los KNN de tipo fino y ponderado. Sin embargo, hay otros algoritmos han obtenido 100% de precisión en la validación y no en entrenamiento, como es el caso de los árboles de decisión.



## II. CÁLCULOS

## 1. [Código del análisis de vibraciones del rodamiento 1](#)

Mediante este código se han obtenido las gráficas visualizadas en el apartado 3.2. de la memoria.

En el apartado mencionado se han visualizado gráficas y junto a ellas la misma gráfica pero visualizándola con más zoom, al ejecutar este código se obtendrán las gráficas con mayor zoom, para obtener la gráfica completa tan solo se ha tenido que comentar o eliminar las líneas con algún “xlim(...)”, las que usaban la función helperPlotCombs y la leyenda en las gráficas que usaban helperPlotCombs.

*%Cargamos datos normales, fallo p.interna, fallo p.externa y en bola*

```
load('Normal_2.mat');
load('IR007_2.mat');
load('OR007@6_2.mat');
load('B007_2.mat');

BPMFI=5.4152*(X107RPM/60);
BPMFO=3.5848*(X132RPM/60); %velocidad en Hz (rps)
FTF=0.39828*(X120RPM/60);
BSF=4.7135*(X120RPM/60);

xnorm = X099_DE_time;
fs = 12000;
tnorm = (0:length(xnorm)-1)/fs;
figure
plot(tnorm, xnorm)
xlabel('Tiempo, (s)')
ylabel('Aceleración (g)')
title('Señal original: Normal')
xlim([1 1.2])

xint=X107_DE_time;
tint = (0:length(xint)-1)/fs;
figure
plot(tint, xint)
xlabel('Tiempo, (s)')
ylabel('Aceleración (g)')
title('Señal original: Fallo pista interna')
xlim([1 1.2])

xext=X132_DE_time;
text = (0:length(xext)-1)/fs;
figure
plot(text, xext)
xlabel('Tiempo, (s)')
ylabel('Aceleración (g)')
title('Señal original: Fallo pista externa')
xlim([1 1.2])
```

```
xbola=X120_DE_time;
tbola = (0:length(xbola)-1)/fs;
figure
plot(tbola, xbola)
xlabel('Tiempo, (s)')
ylabel('Aceleración (g)')
title('Señal original: Fallo en la bola')
xlim([0 1.2])
```

%Espectro de potencia

```
figure
[pnorm, fpnorm] = pspectrum(xnorm, fs);
plot(fpnorm, pnorm)
xlim([0 500])
ncomb = 10;
helperPlotCombs(ncomb, [BPFO BPF1])
xlabel('Frecuencia (Hz)')
ylabel('Espectro (g^2)')
title('Señal original: Normal')
legend('Espectro', 'Armónicos BPFO', 'Armónicos BPF1')
```

```
figure
[pint, fpint] = pspectrum(xint, fs);
plot(fpint, pint)
xlim([0 500])
helperPlotCombs(ncomb, BPF1)
xlabel('Frecuencia (Hz)')
ylabel('Espectro (g^2)')
title('Señal original: Fallo pista interna')
legend('Espectro', 'Armónicos BPF1')
```

```
figure
[pext, fpext] = pspectrum(xext, fs);
plot(fpext, pext)
xlim([0 500])
helperPlotCombs(ncomb, BPFO)
xlabel('Frecuencia (Hz)')
ylabel('Espectro (g^2)')
title('Señal original: Fallo pista externa')
legend('Espectro', 'Armónicos BPFO')
```

```
figure
[pbola, fpbola] = pspectrum(xbola, fs);
plot(fpbola, pbola)
xlim([0 500])
helperPlotCombs(ncomb, BSF)
xlabel('Frecuencia (Hz)')
ylabel('Espectro (g^2)')
```

```
title('Señal original: Fallo en la bola')
legend('Espectro', 'Armónicos BSF')

%Tramo entre picos y envolvente

figure
subplot(2, 1, 1)
plot(tint, xint)
xlim([0.807 0.827])
title('Señal original: Fallo pista interna')
ylabel('Aceleración (g)')
annotation('doublearrow', [0.305 0.55], [0.85 0.85])
%text(0.812, 1, '0.0063 s \approx 1/BPFI, BPFI = 157.96')

subplot(2, 1, 2)
[pEnvint, fEnvint, xEnvint, tEnvint] = envspectrum(xint, fs);
plot(tEnvint, xEnvint)
xlim([0.807 0.827])
xlabel('Tiempo (s)')
ylabel('Aceleración (g)')
title('Envolvente de la señal')

%Lo mismo para datos normales y fallo externa

figure
subplot(2, 1, 1)
plot(tnorm, xnorm)
xlim([0.807 0.827])
title('Señal original: Normal')
ylabel('Aceleración (g)')

subplot(2, 1, 2)
[pEnvnorm, fEnvnorm, xEnvnorm, tEnvnorm] = envspectrum(xnorm, fs);
plot(tEnvnorm, xEnvnorm)
xlim([0.807 0.827])
xlabel('Tiempo (s)')
ylabel('Aceleración (g)')
title('Envolvente de la señal')

figure
subplot(2, 1, 1)
plot(text, xext)
xlim([0.802 0.822])
title('Señal original: Fallo pista externa')
ylabel('Aceleración (g)')
annotation('doublearrow', [0.285 0.652], [0.86 0.86])

subplot(2, 1, 2)
[pEnvext, fEnvext, xEnvext, tEnvext] = envspectrum(xext, fs);
plot(tEnvext, xEnvext)
```

```
xlim([0.802 0.822])
xlabel('Tiempo (s)')
ylabel('Aceleración (g)')
title('Envolvente de la señal')

figure
subplot(2, 1, 1)
plot(tbola, xbola)
xlim([0.807 0.827])
title('Señal original: Fallo en la bola')
ylabel('Aceleración (g)')

subplot(2, 1, 2)
[pEnvbola, fEnvbola, xEnvbola, tEnvbola] = envspectrum(xbola, fs);
plot(tEnvbola, xEnvbola)
xlim([0.807 0.827])
xlabel('Tiempo (s)')
ylabel('Aceleración (g)')
title('Envolvente de la señal')

%Espectro env

figure
plot(fEnvint, pEnvint)
xlim([0 1000])
helperPlotCombs(ncomb, BPF1)
xlabel('Frecuencia (Hz)')
ylabel('Amplitud (g)')
title('Espectro de la envolvente: Fallo pista interna')
legend('Espectro', 'Armónicos BPF1')

%Rod normal

figure
plot(fEnvnorm, pEnvnorm)
helperPlotCombs(ncomb, [BPFO BPF1])
xlim([0 1000])
xlabel('Frecuencia (Hz)')
ylabel('Amplitud (g)')
title('Espectro de la envolvente: Normal')
legend('Espectro', 'Armónicos BPFO', 'Armónicos BPF1')

%Rod fallo externa

figure
plot(fEnvext, pEnvext)
helperPlotCombs(ncomb, BPFO)
xlim([0 1000])
xlabel('Frecuencia (Hz)')
ylabel('Amplitud (g)')
```

```
title('Espectro de la envolvente: Fallo pista externa')
legend('Espectro', 'Armónicos BPFO')

%Fallo en la bola

figure
plot(fEnvbola, pEnvbola)
helperPlotCombs(ncomb, BSF)
xlim([0 1000])
xlabel('Frecuencia (Hz)')
ylabel('Amplitud (g)')
title('Espectro de la envolvente: Fallo en la bola')
legend('Espectro', 'Armónicos BSF')

%filtros

level=9;
figure
kurtogram(xnorm,fs,level)

[~,~,~,fc,~,BW] = kurtogram(xnorm, fs, level);

[pEnvBpf, fEnvBpf] = envspectrum(xnorm, fs, 'FilterOrder', 200, 'Band', [max([fc-BW/2 0])
min([fc+BW/2 0.999*fs/2])]);

figure
plot(fEnvBpf,pEnvBpf)
xlim([0 1000])
helperPlotCombs(ncomb, [BPFI BPFO])
title('Espectro de la envolvente filtrado: Normal')
xlabel('Frecuencia (Hz)')
ylabel('Amplitud (g)')
legend('Espectro', 'Armónicos BPFI', 'Armónicos BPFO')

figure
kurtogram(xint, fs, level)

[~,~,~,fc,~,BW] = kurtogram(xint, fs, level);

[pEnvBpf, fEnvBpf] = envspectrum(xint, fs, 'FilterOrder', 200, 'Band', [max([fc-BW/2 0]) min([fc+BW/2
0.999*fs/2])]);

figure
plot(fEnvBpf,pEnvBpf)
xlim([0 1000])
helperPlotCombs(ncomb, BPFI)
title('Espectro de la envolvente filtrado: Fallo pista interna')
xlabel('Frecuencia (Hz)')
ylabel('Amplitud (g)')
legend('Espectro', 'Armónicos BPFI')
```

```
figure
kurtogram(xext, fs, level)

[~, ~, ~, fc, ~, BW] = kurtogram(xext, fs, level);

[pEnvBpf, fEnvBpf] = envspectrum(xext, fs, 'FilterOrder', 200, 'Band', [max([fc-BW/2 0]) min([fc+BW/2
0.999*fs/2])]);

figure
plot(fEnvBpf,pEnvBpf)
xlim([0 1000])
helperPlotCombs(ncomb, BPF0)
title('Espectro de la envolvente filtrado: Fallo pista externa')
xlabel('Frecuencia (Hz)')
ylabel('Amplitud (g)')
legend('Espectro', 'Armónicos BPF0')

level=10;
figure
kurtogram(xbola, fs, level)

[~, ~, ~, fc, ~, BW] = kurtogram(xbola, fs, level);

[pEnvBpf, fEnvBpf] = envspectrum(xbola, fs, 'FilterOrder', 200, 'Band', [max([fc-BW/2 0])
min([fc+BW/2 0.999*fs/2])]);

figure
plot(fEnvBpf,pEnvBpf)
xlim([0 1000])
helperPlotCombs(ncomb, BSF)
title('Espectro de la envolvente filtrado: Fallo en la bola')
xlabel('Frecuencia (Hz)')
ylabel('Amplitud (g)')
legend('Espectro', 'Armónicos BSF')
```

## 2. Código del análisis de vibraciones del rodamiento 2

```
load('Normal_2.mat');
load('IR007_2FE.mat');
load('OR007@6_2FE.mat');

BPF1=4.9469*(X280RPM/60);
BPF0=3.0530*(X296RPM/60); %velocidad en Hz (rps)

fs=12000;
```

```
xFE=X099_FE_time;

[pEnvFE, fEnvFE, ~, ~] = envspectrum(xFE, fs);

level = 9;
[~, ~, ~, fc, ~, BW] = kurtogram(xFE, fs, level);
[pEnvBpf, fEnvBpf] = envspectrum(xFE, fs, 'FilterOrder', 200, 'Band', [max([fc-BW/2 0]) min([fc+BW/2
0.999*fs/2])]);

figure
subplot(1,2,1)
plot(fEnvFE, pEnvFE)
ncomb = 10;
helperPlotCombs(ncomb, [BPFI BPFO])
xlim([0 1000])
xlabel('Frecuencia (Hz)')
ylabel('Amplitud (g)')
title('Espectro de la envolvente: Rodamiento normal')
legend('Espectro', 'Armónicos BPFI', 'Armónicos BPFO')

subplot(1,2,2)
plot(fEnvBpf, pEnvBpf)
xlim([0 1000])
helperPlotCombs(ncomb, [BPFI BPFO])
xlim([0 1000])
xlabel('Frecuencia (Hz)')
ylabel('Amplitud (g)')
title('Espectro de la envolvente filtrado: Rodamiento normal')
legend('Espectro', 'Armónicos BPFI', 'Armónicos BPFO')

%Fallo interna

xFE = X280_FE_time;

[pEnvFE, fEnvFE, ~, ~] = envspectrum(xFE, fs);

level = 9;
[~, ~, ~, fc, ~, BW] = kurtogram(xFE, fs, level);
[pEnvBpf, fEnvBpf] = envspectrum(xFE, fs, 'FilterOrder', 200, 'Band', [max([fc-BW/2 0]) min([fc+BW/2
0.999*fs/2])]);

figure
subplot(1,2,1)
plot(fEnvFE, pEnvFE)
helperPlotCombs(ncomb, BPFI)
xlim([0 1000])
xlabel('Frecuencia (Hz)')
ylabel('Amplitud (g)')
title('Espectro de la envolvente: Fallo pista interna')
legend('Espectro', 'Armónicos BPFI')
```



```
subplot(1,2,2)
plot(fEnvBpf,pEnvBpf)
xlim([0 1000])
helperPlotCombs(ncomb, BPFi)
xlim([0 1000])
xlabel('Frecuencia (Hz)')
ylabel('Amplitud (g)')
title('Espectro de la envolvente filtrado: Fallo pista interna')
legend('Espectro', 'Armónicos BPFi')

xFE = X296_FE_time;

[pEnvFE, fEnvFE, ~, ~] = envspectrum(xFE, fs);

level = 9;
[~, ~, ~, fc, ~, BW] = kurtogram(xFE, fs, level);
[pEnvBpf, fEnvBpf] = envspectrum(xFE, fs, 'FilterOrder', 200, 'Band', [max([fc-BW/2 0]) min([fc+BW/2 0.999*fs/2])]);

figure
subplot(1,2,1)
plot(fEnvFE, pEnvFE)
helperPlotCombs(ncomb, BPFo)
xlim([0 1000])
xlabel('Frecuencia (Hz)')
ylabel('Amplitud (g)')
title('Espectro de la envolvente: Fallo pista externa')
legend('Espectro', 'Armónicos BPFo')

subplot(1,2,2)
plot(fEnvBpf,pEnvBpf)
xlim([0 1000])
helperPlotCombs(ncomb, BPFo)
xlim([0 1000])
xlabel('Frecuencia (Hz)')
ylabel('Amplitud (g)')
title('Espectro de la envolvente filtrado: Fallo pista externa')
legend('Espectro', 'Armónicos BPFo')
```

### 3. Código obtención de características con ancho de banda personalizado

Este código se ha usado para obtener las amplitudes del espectro de la envolvente de la señal en las frecuencias características de fallo, para cada ensayo se ha sustituido en la primera línea el load que tiene el nombre con el archivo de datos del ensayo que interesaba analizar, la variable que tiene la velocidad de giro (en RPM) que en este caso es "X107RPM" y la variable x por la variable que contiene los datos de la señal original correspondiente al ensayo analizado, que en este caso es "X107\_DE\_time".

Destacar que la envolvente de la señal se calcula con un ancho de banda personalizado, obtenido mediante el kurtograma.

**%Frecuencias de fallo características**

```
load('IR007_2.mat');
BPFI=5.4152*(X107RPM/60);
BPFO=3.5848*(X107RPM/60); %velocidad en Hz (rps)
FTF=0.39828*(X107RPM/60);
BSF=4.7135*(X107RPM/60);

x=X107_DE_time;
fs=12000;

%Ancho de banda
level=9;
[~, ~, ~, fc, ~, BW] = kurtogram(x, fs, level);

[pEnvpBpf, fEnvBpf] = envspectrum(x, fs, 'FilterOrder', 200, 'Band', [max([fc-BW/2 0]) min([fc+BW/2 0.999*fs/2])]);
deltaf = fEnvBpf(2) - fEnvBpf(1);

AmplitudBPFI = max(pEnvpBpf((fEnvBpf > (BPFI-5*deltaf)) & (fEnvBpf < (BPFI+5*deltaf))));
AmplitudBPFO = max(pEnvpBpf((fEnvBpf > (BPFO-5*deltaf)) & (fEnvBpf < (BPFO+5*deltaf))));
```

#### 4. Código obtención de características sin ancho de banda personalizado

Este código tan solo se diferencia con el código del punto 2 en que no se utiliza el ancho de banda que calcula el kurtograma para obtener la envolvente de la señal.

```
load('IR007_2FE.mat');
BPFI=4.9469*(X280RPM/60);
BPFO=3.0530*(X280RPM/60); %velocidad en Hz (rps)
FTF=0.3817*(X280RPM/60);
BSF=3.9874*(X280RPM/60);

x=X280_FE_time;
fs=12000;

[pEnvpBpf, fEnvBpf] = envspectrum(x, fs);
deltaf = fEnvBpf(2) - fEnvBpf(1);

AmplitudBPFI = max(pEnvpBpf((fEnvBpf > (BPFI-5*deltaf)) & (fEnvBpf < (BPFI+5*deltaf))));
AmplitudBPFO = max(pEnvpBpf((fEnvBpf > (BPFO-5*deltaf)) & (fEnvBpf < (BPFO+5*deltaf))));
```

## 5. [Código de la función helperPlotCombs](#)

Este es un Código de Matlab el cual se ha usado para ciertas gráficas.

```
function helperPlotCombs(ncomb, f)
%HELPERPLOTCOMBS Plot harmonic cursors on a power spectrum plot

% Copyright 2017 The MathWorks, Inc.
ylim = get(gca, 'YLim');
ylim(ylim);
ycomb = repmat([ylim nan], 1, ncomb);
hold(gca, 'on')
for i = 1:length(f)
    xcomb = f(i)*(1:ncomb);
    xcombs = [xcomb; xcomb; nan(1, ncomb)];
    xcombs = xcombs(:);
    plot(xcombs, ycomb, '--')
end
hold(gca, 'off')
end
```

## III. PRESUPUESTO

En este apartado se realizará una valoración económica del trabajo desarrollado.

### 1. Presupuestos parciales

Puesto que no se conoce exactamente algunos de los componentes que forman el banco de ensayo, se ha consultado en internet precios de componentes lo más parecidos posibles a los del banco.

Primero se ha realizado el presupuesto de los recursos materiales y digitales, los cuales son los que forman parte del banco de ensayo utilizado para obtener los datos.

RECURSOS MATERIALES Y DIGITALES			
Descripción	Cantidad (uds)	Precio unitario (€/ud)	Importe (€)
Rodamiento 6205-2RS JEM SFK	1	5,90	5,90
Rodamiento 6203-2RS JEM SFK	1	3,89	3,89
Motor eléctrico 2HP	1	155,30	155,30
Acelerómetros	3	215,75	647,25
Grabador DAT 16 canales	1	489,00	489,00
Codificador de par	1	174,60	174,60
Dinamómetro	1	516,91	516,91
Ordenador portátil ASUS	1	659,27	659,27
Licencia anual de Matlab	1	800	800
<b>Total</b>			<b>1992,85</b>

Tabla 16. Presupuesto de los recursos materiales

A continuación, se ha realizado el presupuesto de los recursos humanos que han participado en el trabajo.

RECURSOS HUMANOS			
Descripción	Cantidad (h)	Precio unitario (€/h)	Importe (€)
Ingeniero industrial en formación	300	15	4500
Ingeniero industrial supervisor	50	25	1250
<b>Total</b>			<b>5750</b>

Tabla 17. Presupuesto de los recursos humanos

Después se ha calculado el presupuesto de los gastos de envío de los recursos materiales.

Los rodamientos se envían juntos ya que se compran en la misma tienda. Algunos recursos materiales tienen incluidos en su precio de compra los gastos de envío, a estos se les ha asignado un importe nulo.

GASTOS DE ENVÍO DE RECURSOS MATERIALES	
Descripción	Importe (€)
Rodamiento 6205-2RS JEM SFK y rodamiento 6203-2RS JEM SFK	11,98
Motor eléctrico 2HP	20,96
Acelerómetros	0,00
Grabador DAT 16 canales	0,00
Codificador de par	0,00
Dinamómetro	0,00
<b>Total</b>	<b>32,94</b>

Tabla 18. Presupuesto de los gastos de envío de recursos materiales

## 2. Presupuesto total

Por último se sumaron todos los presupuestos, junto un IVA del 21%, obteniendo así el presupuesto total o presupuesto base de licitación del trabajo.

PRESUPUESTO TOTAL	
Descripción	Importe (€)
Recursos materiales y digitales	3452,12
Recursos humanos	5750
Gastos de envío de recursos materiales	32,94
<b>Total (sin IVA)</b>	<b>9235,06</b>
I.V.A.(21%)	1939,36
<b>Presupuesto base de licitación</b>	<b>11174,42</b>

Tabla 19. Presupuesto total del trabajo

El presupuesto base de licitación del trabajo estimado es de ONCE MIL CIENTO SETENTA Y CUATRO EUROS CON CUARENTA Y DOS CÉNTIMOS.

## REFERENCIAS

- 123Rodamiento. (s.f.). *123Rodamiento*. Obtenido de [https://www.123rodamiento.es/rodamientos-6205-2RS-SKF?gclid=CjwKCAjwieuGBhAsEiwA1Ly\\_nQgXafg06wdbUWtx\\_3hI4HVG1MXv29gKJILL\\_\\_JnPLSRjGUFqU1s3hoCOM4QAvD\\_BwE&gclsrc=aw.ds#container-tech-schema](https://www.123rodamiento.es/rodamientos-6205-2RS-SKF?gclid=CjwKCAjwieuGBhAsEiwA1Ly_nQgXafg06wdbUWtx_3hI4HVG1MXv29gKJILL__JnPLSRjGUFqU1s3hoCOM4QAvD_BwE&gclsrc=aw.ds#container-tech-schema)
- 123Rodamiento. (s.f.). *123Rodamiento*. Obtenido de <https://www.123rodamiento.es/rodamiento-6203-2RS-SKF#container-tech-schema>
- Automation24*. (s.f.). Obtenido de [https://www.automation24.es/encoder-incremental-ifm-electronic-ro3100?previewPriceListId=1&gclid=CjwKCAjwieuGBhAsEiwA1Ly\\_nWlyoo5gJFbI5h9rDvMf4z0xNmxb4Ba6gLFGsPdC72BHcB8PY8OQ6RoCNYQQAvD\\_BwE](https://www.automation24.es/encoder-incremental-ifm-electronic-ro3100?previewPriceListId=1&gclid=CjwKCAjwieuGBhAsEiwA1Ly_nWlyoo5gJFbI5h9rDvMf4z0xNmxb4Ba6gLFGsPdC72BHcB8PY8OQ6RoCNYQQAvD_BwE)
- Ballesteros, F. (4 de Agosto de 2014). *Preditécnico - Diagnóstico Predictivo vs. Mantenimiento Predictivo*. Obtenido de <http://www.preditecnico.com/2014/08/diagnostico-predictivo-vs-mantenimiento.html>
- Band, A. (s.f.). *Towards data science - Multi-class Classification - One-vs-all & One-vs-one*. Obtenido de <https://towardsdatascience.com/multi-class-classification-one-vs-all-one-vs-one-94daed32a87b>
- Barszcz, T. (2019). *Vibration-Based Condition Monitoring of Wind Turbines*. Springer.
- BESA GONZÁLVEZ, A., & VALERO CHULIÁ, F. (2016). *Diseño de Máquinas*. Valencia: Universitat Politècnica de València .
- Ebay*. (s.f.). Obtenido de [https://www.ebay.es/itm/320970567136?\\_trkparms=ispr%3D1&hash=item4abb562de0:g:S70AAOSwu2lgEyk6&amdata=enc%3AAQAGAAACgPYe5NmHp%252B2JMhMi7yxGiTJkPrKr5t53CooMSQt2orsSOspISiqug7sS7XxKGLiF3zjQeY8qRKQIoNKSpCEDvEajsoZtMMmVBh%252F0oh0tQ3dh1WR2paPaZhSw7wDi43AZfK](https://www.ebay.es/itm/320970567136?_trkparms=ispr%3D1&hash=item4abb562de0:g:S70AAOSwu2lgEyk6&amdata=enc%3AAQAGAAACgPYe5NmHp%252B2JMhMi7yxGiTJkPrKr5t53CooMSQt2orsSOspISiqug7sS7XxKGLiF3zjQeY8qRKQIoNKSpCEDvEajsoZtMMmVBh%252F0oh0tQ3dh1WR2paPaZhSw7wDi43AZfK)
- Fernandez, A. (2021). *Power-MI*. Obtenido de <https://power-mi.com/es/content/componentes-y-frecuencias-de-fallo-de-un-rodamiento>
- García, Á. F. (2016). *MATLAB Análisis de datos - Transformada rápida de Fourier (I)*. Obtenido de [http://www.sc.ehu.es/sbweb/fisica3/datos/fourier/fourier\\_1.html](http://www.sc.ehu.es/sbweb/fisica3/datos/fourier/fourier_1.html)
- González, A. (s.f.). *cleverdata*. Obtenido de <https://cleverdata.io/que-es-machine-learning-big-data/>
- Hernández-Montero, F. E., & Gutiérrez-García, M. (s.f.). *Scielo. Enfoques del análisis de envolvente al procesamiento de vibraciones para el diagnóstico de maquinarias*. Obtenido de [http://scielo.sld.cu/scielo.php?script=sci\\_arttext&pid=S1815-59442010000100004](http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S1815-59442010000100004)
- Made-in-China. (s.f.). *Made-in-China*. Obtenido de [https://es.made-in-china.com/co\\_flowgroup/product\\_6205-2RS-Jem-SKF-Benefits-of-Deep-Groove-Ball-Bearing-16mm-10-mm-25mm-Deep-Groove-Ball-Bearing-52X25X15-7-7-8\\_enuoengy.html](https://es.made-in-china.com/co_flowgroup/product_6205-2RS-Jem-SKF-Benefits-of-Deep-Groove-Ball-Bearing-16mm-10-mm-25mm-Deep-Groove-Ball-Bearing-52X25X15-7-7-8_enuoengy.html)

- MathWorks. (s.f.). *MathWorks Help Center Rolling Element Bearing Fault Diagnosis*. Obtenido de [https://es.mathworks.com/help/predmaint/ug/Rolling-Element-Bearing-Fault-Diagnosis.html?s\\_tid=srchtitle](https://es.mathworks.com/help/predmaint/ug/Rolling-Element-Bearing-Fault-Diagnosis.html?s_tid=srchtitle)
- Mouser electronics. (s.f.). Obtenido de [https://www.mouser.es/ProductDetail/Amphenol-Wilcoxon/786A?q=s=l7cgNqFNU1jUbe6sZogbMA==&mgh=1&vip=1&gclid=CjwKCAjwieuGBhAsEiwA1Ly\\_nTsKjU8TmVqXHhO1uXQsCNv0aaCwp7HUaHMleG71gx9Q\\_r\\_g2jZTrxoCuusQAvD\\_BwE](https://www.mouser.es/ProductDetail/Amphenol-Wilcoxon/786A?q=s=l7cgNqFNU1jUbe6sZogbMA==&mgh=1&vip=1&gclid=CjwKCAjwieuGBhAsEiwA1Ly_nTsKjU8TmVqXHhO1uXQsCNv0aaCwp7HUaHMleG71gx9Q_r_g2jZTrxoCuusQAvD_BwE)
- Roman, V. (s.f.). *Medium*. Obtenido de <https://medium.com/datos-y-ciencia/algoritmos-naive-bayes-fundamentos-e-implementaci%C3%B3n-4bcb24b307f>
- RS. (s.f.). Obtenido de <https://es.rs-online.com/web/p/dinamometros/1113689/>
- SPORT, I. (2021). *ISB SPORT*. Obtenido de <https://isbsport.com/partes-de-un-rodamiento/>
- The MathWorks, I. (s.f.). *Mathworks*. Obtenido de [https://es.mathworks.com/help/pdf\\_doc/stats/stats.pdf](https://es.mathworks.com/help/pdf_doc/stats/stats.pdf)
- Thomann. (s.f.). Obtenido de [https://www.thomann.de/es/behinger\\_s16.htm?glp=1&gclid=CjwKCAjwieuGBhAsEiwA1Ly\\_nUpIFU\\_T48PwGTxLs\\_4SURDJDQJHS\\_VQ3pmp0dw4YdzvkgPq6MlbhoCHhkQAvD\\_BwE](https://www.thomann.de/es/behinger_s16.htm?glp=1&gclid=CjwKCAjwieuGBhAsEiwA1Ly_nUpIFU_T48PwGTxLs_4SURDJDQJHS_VQ3pmp0dw4YdzvkgPq6MlbhoCHhkQAvD_BwE)
- University, C. W. (s.f.). *Case Western Reserve University Bearing Data Center Website*. Obtenido de <https://csegroups.case.edu/bearingdatacenter/pages/welcome-case-western-reserve-university-bearing-data-center-website>
- Wikipedia. (s.f.). *Wikipedia - K vecinos más próximos*. Obtenido de [https://es.wikipedia.org/wiki/K\\_vecinos\\_m%C3%A1s\\_pr%C3%B3ximos#Posibles\\_variantes\\_del\\_algoritmo\\_b%C3%A1sico](https://es.wikipedia.org/wiki/K_vecinos_m%C3%A1s_pr%C3%B3ximos#Posibles_variantes_del_algoritmo_b%C3%A1sico)
- Wikipedia. (s.f.). *Wikipedia - Matriz de confusión*. Obtenido de [https://es.wikipedia.org/wiki/Matriz\\_de\\_confusi%C3%B3n](https://es.wikipedia.org/wiki/Matriz_de_confusi%C3%B3n)
- Wikipedia. (s.f.). *Wikipedia - SCADA*. Obtenido de <https://es.wikipedia.org/wiki/SCADA>
- Wikipedia. (s.f.). *Wikipedia - Sobreajuste*. Obtenido de <https://es.wikipedia.org/wiki/Sobreajuste>
- Wikipedia. (s.f.). *Wikipedia Máquinas de vectores de soporte*. Obtenido de [https://es.wikipedia.org/wiki/M%C3%A1quinas\\_de\\_vectores\\_de\\_soporte](https://es.wikipedia.org/wiki/M%C3%A1quinas_de_vectores_de_soporte)
- Wikipedia. (s.f.). *Wikipedia Regresión logística*. Obtenido de [https://es.wikipedia.org/wiki/Regresi%C3%B3n\\_log%C3%ADstica](https://es.wikipedia.org/wiki/Regresi%C3%B3n_log%C3%ADstica)