

AI Techniques Applied to Diagnosis of Vibrations Failures in Wind Turbines

J. Vives, E. Quiles, and E. García

Abstract—Supervision and fault diagnosis in wind turbines using automatic learning techniques allow early detection of the degeneration of the components, as well as the detection and diagnosis of sudden failures. This contribution evaluates different machine learning methodologies to predict, detect and diagnose electrical and mechanical failures of wind turbines. An integrated monitoring and diagnostic system is proposed using automatic learning algorithms adapted to the different components and faults of the wind turbine.

Index Terms—Wind turbines, Machine learning, Deep learning, Fault detection, Fault diagnosis, Condition monitoring.

I. INTRODUCCIÓN

EL aumento significativo del sector de energía renovables, especialmente en la energía eólica, así como la gran cantidad de datos que generan las mismas están cambiando la perspectiva energética. Esta creciente disponibilidad de datos está modificando la forma en que se toman las decisiones en la industria en áreas importantes como la programación [1], la gestión del mantenimiento [2], [3] y la mejora de la calidad [4]. Se ha demostrado que los enfoques de Machine Learning brindan soluciones cada vez más efectivas en estas áreas, facilitados por las crecientes capacidades del hardware, las soluciones basadas en la nube y los nuevos algoritmos de última generación [5].

En los últimos años el sector eólico ha aumentado entorno al 20% su producción [6], con lo que lleva a los investigadores e ingenieros a desarrollado nuevas técnicas específicas para su mantenimiento, especialmente si se encuentran en una ubicación offshore. En la actualidad, se requiere de métodos eficientes de supervisión avanzada y diagnóstico de fallos para la mejora de la fiabilidad, seguridad y la rentabilidad económica de aerogeneradores. Las principales metodologías de fallos empleadas actualmente en el mantenimiento de un aerogenerador [7] son el análisis espectral y arboles de fallos, pero debido al gran avance tecnológico de la sociedad, con todo lo que conlleva, conectividad, Smart, generación de datos esta

dando paso a una nueva corriente en el campo de mantenimiento, mediante la inteligencia artificial (IA) o al Machine Learning.

La implementación de esta serie de metodologías de mantenimiento aplicadas a algoritmos inteligentes, tienen como fin la anticipación, detección y clasificación de las anomalías de los componentes mecánicos de la maquina.

Una de las principales causas de averías en aerogeneradores se debe a la presencia de vibraciones en el sistema. Dicho sistema esta constituido por múltiples piezas que trabajan en conjunto. Las vibraciones presentes en éstas, no son más que la suma de todas las señales de vibración provenientes de cada una de sus partes, pero en muchas ocasiones puede significar el deterioro o desgaste de los componentes. Los fallos que se pueden detectar por medio de las vibraciones suelen ser debidos a un desajuste mecánico, problemas eléctricos, defectos de engranajes o rodamientos. Los rodamientos son elementos que presentan un mayor desgaste debido a que la posición de los elementos rodantes cambia continuamente con respecto a la carga, provocando un comportamiento que depende de la velocidad de rotación [8]. Además, la rugosidad o las imperfecciones geométricas presentes en la superficie también causan vibraciones. Las vibraciones no solo se generan en condiciones operativas normales, sino que también se deben a fallas, como fallas de canalización exterior e interior, fallas de elementos rodantes, fallas de jaula, desequilibrio y desalineación.

Con el fin de poder detectar un fallo de los rodamientos debido a las vibraciones mecánicas se suele utilizar el análisis espectral de frecuencias. Esta técnica requiere que el espectro de frecuencia se obtenga conjuntamente con las frecuencias fundamentales de los rodamientos. Mediante la monitorización de la amplitud de las frecuencias permiten detectar anomalías en los mismos [9], [10].

Para analizar y prevenir esta serie de fallos se esta empleando la metodología de IA comentada anteriormente. Estos métodos deben ser validados de forma adecuada antes de su costosa implementación en el sistema real [11]. En este sentido, la utilización de prototipos o bancadas de pruebas es conveniente para la validación de técnicas de diagnóstico de fallos.

Son diversos los campos de energías renovables que utilizan prototipos para su estudio y mejora. El objetivo de estos prototipos es el de ayudar a conocer el funcionamiento de estos sistemas y utilizarlo para desarrollar nuevas técnicas, hacer estudios, etc.

Una parada por avería de un aerogenerador, o varios, puede suponer una cuantiosa pérdida de dinero por dos partes: en primer lugar, por el coste de cambiar el componente o componentes dañados, y en segundo lugar por la energía que no se va a producir mientras el aerogenerador se encuentre parado, cuya parada podría ocurrir en momentos de máxima producción

Esta investigación no recibió ninguna subvención específica de ninguna agencia de financiación de sectores públicos, comerciales o sin fines de lucro.

J. Vives estudiante de la Universitat Politècnica de València, está investigando con el Instituto de Automatización e Informática Industrial, Camino de Vera, s / n 46022 Valencia (e-mail: javifus@posgrado.upv.es).

E. Quiles, investigador y docente en el Instituto de Automatización e Informática Industrial de la Universitat Politècnica de València, Camino de Vera, s / n 46022 Valencia (e-mail: equiles@isa.upv.es).

E. García, investigador y docente en el Instituto de Automatización e Informática Industrial de la Universitat Politècnica de València, Camino de Vera, s / n 46022 Valencia (e-mail: egarciam@isa.upv.es).

de energía. Por estas razones, las técnicas de supervisión y detección y diagnóstico de fallos resultan imprescindibles en sistemas eólicos, en donde los costes en reparaciones y mantenimiento son muy elevados, especialmente en emplazamientos offshore, siendo de vital importancia que la máquina esté parada el menor tiempo posible. Al mismo tiempo, la administración eficiente de las actividades de mantenimiento se está volviendo esencial para disminuir los costos asociados con el tiempo de inactividad y los productos defectuosos.

Hasta la fecha, los investigadores e ingenieros han desarrollado técnicas específicas para aerogeneradores, según lo revisado en [12], [13], [14]. Tradicionalmente, los sistemas de monitoreo de condición para turbinas eólicas se han centrado en la detección de fallas en el generador, así como en su estructura, mediante técnicas de diagnóstico convencionales [15], [16]. En nuestro caso, comparándolo con lo realizado hasta ahora, este prototipo permite una detección, supervisión y anticipación de fallos, mediante la aplicación de algoritmos inteligentes, capaces de anticiparse y prevenir los posibles fallos del aerogenerador utilizando una metodología de inteligencia artificial mediante el uso de machine learning. [17] Por lo tanto, en este documento desarrollamos un método de aprendizaje de características para detectar de manera autónoma diferentes fallas de rodamientos utilizando el análisis de vibraciones.

En este artículo presentamos la aplicación de un algoritmo inteligente aplicado un prototipo de aerogenerador para la supervisión y diagnóstico de fallos. En la siguiente sección se da una revisión de la literatura. Posteriormente, se discuten el procedimiento de captura de datos y el conjunto de datos. A continuación, se evalúan y comparan los resultados de los clasificadores utilizados. Finalmente, se presentan algunas conclusiones relevantes del estudio.

II. ANTECEDENTES TEÓRICOS

Para el objetivo principal de reducir los costos operativos, prolongar la vida útil de las máquinas y mejorar el tiempo de funcionamiento operativo, se requiere un sistema de monitorización avanzado.

Estos sistemas, permiten inspeccionar el estado de la máquina con el fin de detectar componentes defectuosos. Los componentes que a menudo son la principal fuente de fallas en máquinas rotativas, como los aerogeneradores, son los rodamientos de elementos rodantes [18]. Para monitorear la condición de los componentes de la máquina, tales como rotores, ejes, acoplamientos, engranajes y también rodamientos, a menudo se emplean acelerómetros para la detección de vibraciones. La presencia de los elementos rodantes en los rodamientos induce vibraciones inherentes al sistema. Además, las imperfecciones geométricas o la rugosidad de la superficie también las generan. Las vibraciones no solo se generan en condiciones operativas normales, sino que también se deben a fallas, como fallas de canalización exterior, fallas de canalización interior, fallas de elementos rodantes, fallas de jaula, desequilibrio y desalineación. Con el fin principal de detectar o anticiparse automáticamente a componentes defectuosos, se pueden usar algoritmos de aprendizaje automático. Esta serie de algoritmos utilizan una cadena de datos para construir un modelo que puede detectar

diferentes condiciones. Los datos que se emplean para entrenar los modelos son características que son construidas y extraídas por un experto a partir de datos sin procesar. A continuación, se presentan las técnicas que de estudio empleadas.

A. Análisis Frecuencial

Esta es la principal metodología empleada hasta ahora para la detección de vibraciones en los rodamientos. Esta técnica requiere que el espectro de frecuencia se calcule junto con las frecuencias fundamentales de los rodamientos. La amplitud en estas frecuencias se puede monitorear para detectar anomalías. Sin embargo, tal técnica tiene muchas desventajas. En primer lugar, los cálculos de frecuencia suponen que no hay deslizamiento, es decir, los elementos rodantes solo ruedan en las pistas de rodadura. A menudo, un rodamiento sufre una combinación de rodadura y deslizamiento. Como consecuencia, las frecuencias calculadas pueden diferir ligeramente, alrededor del 5%, en comparación con las frecuencias reales [19]. En segundo lugar, si se producen varias fallas simultáneamente, las frecuencias generadas pueden sumarse y restarse, ocultando frecuencias importantes [20]. En tercer lugar, también existe la posibilidad de que se induzca la interferencia debido a fuentes adicionales de vibración, es decir, a la holgura del cojinete, lo que dificulta las características útiles. Por último, algunas fallas, como las fallas relacionadas con la lubricación, ni siquiera se manifiestan como una nueva frecuencia cíclica [19], lo que las hace muy difíciles de detectar a través de las técnicas tradicionales de análisis de vibración.

B. Deep Learning

Esta vertiente utiliza parte de la metodología empleada en Machine Learning (Fig. 1) mediante el uso de redes neurales que se compone de un número de niveles jerárquicos, caracterizados por la constitución de múltiples capas de procesamiento no lineal. Muchos algoritmos de aprendizaje profundo han sido diseñados para abordar problemas de aprendizaje no supervisados, mediante un entrenamiento previo sin supervisión distribuido por capas, seguido de un ajuste supervisado, debido a la dificultad que presenta la alta dimensionalidad de las variables aleatorias que se modelan en el aprendizaje no supervisado [21]. Hasta la fecha, existen varias arquitecturas de aprendizaje profundo tales como las redes neuronales o representaciones gráficas. Esta área se encuentra en constante evolución.

C. Machine Learning

El aprendizaje automático para la detección de fallos en aerogeneradores se centra en dos tareas principales, por un lado, en la detección de anomalías y por otra la clasificación de fallos. Esta técnica permite detectar el fallo con prontitud o anticiparlo, ayudando a que se tomen medidas correctivas en tiempos mínimos, lo cual incrementa de forma considerable el nivel de fiabilidad y seguridad del sistema.

Actualmente existen dos métodos de aprendizaje automático, el supervisado y el no supervisado. El aprendizaje automático supervisado es con mucho el más común en una amplia gama de casos de uso de la industria [22]. La diferencia fundamental es que con el aprendizaje supervisado, la salida de su algoritmo ya es conocida, mientras que en el no supervisado no lo es. Todo lo que se necesita hacer es resolver el proceso necesario para obtener de su entrada, a su salida. Este suele ser el caso

cuando un algoritmo se "enseña" a partir de un conjunto de datos de entrenamiento. Por el contrario, el aprendizaje automático no supervisado es un proceso más complejo, debido a que resuelve problemas utilizando solo los datos de entrada y los mecanismos lógicos de encendido / apagado binarios en los que se basan todos los sistemas informáticos. Sin ningún dato de referencia en absoluto.

Con el fin de poder aplicar cualquier tipo de aprendizaje, previamente debe existir una clasificación de los datos que se pretenden emplear [23], [24]. Para ello en la literatura existen diferentes algoritmos clasificadores, los cuales reciben como entrada cierta información de un objeto, siendo capaz de poder indicar la categoría o clase a que pertenece de entre un número acotado de clases posibles. Por lo tanto, un clasificador funciona en dos fases:

- En una primera fase es entrenado, es decir, recibe una gran cantidad de datos de ejemplo y su clasificación correcta, de forma que se pueden ajustar los parámetros del algoritmo para un funcionamiento óptimo.
- Cuando ya está entrenado es cuando ya funciona como se ha descrito anteriormente: recibe una serie de datos de entrada y da la clasificación correspondiente como salida.

Para este estudio se han empleado las técnicas de K-Nearest neighbour (KNN) y Support Vector Machines (SVM). En las tablas 1 y 2, se especifican algunas de las características más destacada de estas dos metodologías.

D. K-Nearest Neighbour (KNN)

Se trata de un algoritmo de aprendizaje basado en el principio de que las instancias dentro de un conjunto de datos generalmente existirán cerca de otras instancias con propiedades similares [25]. Esta metodología no genera un modelo fruto del aprendizaje con datos de entrenamiento, sino que el aprendizaje sucede en el mismo momento en el que se prueban los datos de test. A este tipo de algoritmos también se les conoce como lazy learning methods [26].

Su funcionamiento es muy simple, para un grupo de entrenamiento determinado de instancias clasificadas $T =$

$[(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)]$, donde x_i es el vector de características de la instancia no etiquetada, y_i es la etiqueta y $y_i = c_1, c_2, \dots, c_K$, $i=1, 2, \dots, N$. Para una muestra de entrenamiento (x, y) , el algoritmo k-NN busca las k instancias más cercanas a x basadas en una métrica de distancia dada. El área que contiene estas k instancias está representada por $N_k(x)$. Por lo tanto, la etiqueta de la muestra de prueba x se puede calcular según las reglas de decisión:

$$y = \underset{c_j}{\operatorname{argmax}} \sum_{\substack{x_i \in N_k(x) \\ i = 1, 2, \dots, K}} I(y_i = c_j), \quad i = 1, 2, \dots, N; \quad j = 1, 2, \dots, K \quad (1)$$

donde I es la función de indicador.

Si las instancias están etiquetadas mediante un etiquetador, entonces la etiqueta de una instancia no clasificada puede ser obtenida mediante el análisis de sus vecinos más cercanos, tal y como se muestra en la Fig. 1 [27].




Fig. 1. Diagrama de K-NN con diferentes muestras.

Hay tres conceptos básicos en el algoritmo k-NN: el número de instancias medidas k , la regla de decisión para la clasificación y la distancia métrica.

TABLA I
INTELIGENCIA ARTIFICIAL: VENTAJAS Y LIMITACIONES

Algorithm	Ventajas	Limitaciones
<i>k-NN</i>	Fácil de implementar Se puede usar tanto para clasificación como para regresión	Gran cómputo Necesita mucho espacio de almacenamiento La selección de k influye en la clasificación
<i>Deep learning</i>	Características de aprendizaje y reconocimiento de fallas automáticamente No necesita el extractor de funciones	Necesidades de muestras grandes. No tiene significado físico Mucho entrenamiento
<i>SVM</i>	Alta precisión de clasificación Puede lidiar con características de alta dimensión	Baja eficiencia para big data Sin significado físico

TABLA II
COMPARACIÓN DE RENDIMIENTO

	<i>SVM</i>	<i>k-NN</i>	<i>Deep Learning</i>
Velocidad de clasificación	****	*	**
Precisión en general	****	**	****
Robustez al ruido	**	*	****
sobreajuste	**	***	***
Robustez a los parámetros	*	***	**
Explicación física	*	***	*

MACHINE LEARNING



DEEP LEARNING



Fig. 3. Comparativa entre la metodología de Machine y Deep Learning.

E. Support Vector Machines

El SVM es un algoritmo de clasificación binario. A partir de un conjunto de puntos de 2 tipos en el lugar N-dimensional, este algoritmo origina un hiperplano $f(x)=0$ dimensional para separar esos puntos en 2 grupos [28], [29].

$$y = f(x) = W^T x + b = \sum_{i=1}^N W_i x_i + b \tag{2}$$

donde W es un vector N-dimensional y b es un escalar. El hiperplano de separación óptimo es el hiperplano de separación que se crea con la máxima distancia entre el plano y los datos más cercanos. En la Fig. 2 se muestra dicho hiperplano.




Fig. 2. Hiperplano óptimo para una clasificación binaria por SVM.

F. Modelos Basados en Sensores Múltiples

La disponibilidad de grandes conjuntos de datos de muchos sensores ha llevado a los investigadores al estudio de una nueva metodología para el diagnóstico y pronóstico de equipos de sensores múltiples. Los métodos de fusión de sensores heterogéneos son aplicados a sistemas bastante complejos, debido a que deben monitorear y controlar simultáneamente múltiples tipos de variables, como por ejemplo las vibraciones o corrientes de un aerogenerador.

En estudios recientes de en este campo [25], [26] se consiguen lograr mejores resultados de predicción y además permite una detección de anomalías más precisa.

III. METODOLOGÍA

En primer lugar, en esta sección se describen las características técnicas de la maqueta empleada, así como el sistema de adquisición de datos empleado en el análisis de vibraciones. Y por otra parte se realiza una comparativa de los resultados obtenidos a partir de las técnicas comentadas en el apartado anterior.

A. Prototipo

El uso de pequeños prototipos de aerogeneradores (Fig. 2) son muy útiles e importantes para el diagnóstico de fallos de los componentes que lo constituyen, ya que proporciona la posibilidad de detectar el deterioro y desgaste de las piezas, así como los efectos que produce la rotura de algún componente en el resto del sistema [27], [28]. Con este objetivo, el sistema diseñado permite el intercambio, sin mucha dificultad, de piezas por otras rotas o desgastadas, lo que facilita ensayar las técnicas de diagnóstico sin necesidad de esperar a que el componente se deteriore por el paso del tiempo.




Fig. 4. Distribución de componentes en el prototipo.

Las características de los componentes utilizados se indican en la Tabla 3.

TABLA III
COMPONENTES DEL PROTOTIPO

Moto-reductor	<ul style="list-style-type: none"> ○ Motor eléctrico: 0,75 Kw (1 Hp) con ventilación forzada. ○ Caja reductora: tipo sin-fin / corona, con relación 50:1.
Multiplicadora	<ul style="list-style-type: none"> ○ 3 etapas planetarias ○ Multiplicación total de 1/51.6
Eje rápido	<ul style="list-style-type: none"> ○ Velocidad que oscila entre 0 y 1500 rpm
Generador	<ul style="list-style-type: none"> ○ Potencia máxima de 140 w ○ Tensión de salida trifásica (380 Vac entre fases – 230 Vac entre fase y neutro). ○ Tensión máxima de excitación de 30 Vdc

B. Adquisición de Datos

Los sensores dispuestos para la medida de las vibraciones son acelerómetros. Se trata de acelerómetros de propósito general con conexión de dos pines MIL-C-5015 NI. Se ha empleado la tarjeta de adquisición PCI-4472B [29], optimizada para medidas de vibración. Ofrece adquisición de señal dinámica (DSA) de ocho canales para realizar medidas de alta precisión en el dominio de la frecuencia.

Los canales de entrada incorporan acondicionamiento de señales piezoeléctrico integrado (IEPE) para acelerómetros y micrófonos. Los ocho canales de entrada digitalizan simultáneamente las señales de entrada sobre un ancho de banda desde DC a 45kHz. En el sistema de adquisición se utilizan dos módulos PCI-4472B ya que, como se verá más adelante, se han instalado un total de 10 acelerómetros sobre el prototipo, y cada una de las tarjetas solo dispone de 8 entradas. Respecto al generador, se considera deseable emplazar los sensores en el rodamiento de entrada del mismo para observar las vibraciones en el acoplamiento del generador con el eje rápido. En cuanto a la multiplicadora, basándonos en las técnicas de seguimiento de estado y el diseño de la máquina, los sensores se han situado de forma separada en cada una de las etapas, permitiendo así analizar la propagación de la señal entre ellas, y también cómo afecta cada fallo a las vibraciones que se producen en cada una de las etapas [30], [31].

El rodamiento situado en el eje lento del prototipo también es considerado un punto conveniente para la toma de medidas. Además de permitir estudiar la señal en funcionamiento normal



(a)



(b)

Fig. 6: Ejemplos de diferentes condiciones de rodamientos (a) Rotura de la rodadura (b) Exceso de lubricante.

y el propio deterioro del componente a través de su uso continuado, este elemento puede ser cambiado por otro rodamiento deteriorado y estudiar así las características de la señal en condiciones de fallo [32], [33].

1. Moto-reductor
2. Eje lento
3. Multiplicadora
4. Eje rápido
5. Generador
6. Silent-blocks
7. Tipo de entrada
8. Cuadro eléctrico
9. Anemómetro

Para incluir en la aplicación la funcionalidad de controlar desde el ordenador la velocidad de giro de la máquina y poder aplicar velocidades distintas de las fijas que permiten los mandos manuales, así como permitir aplicar perfiles de viento sobre el prototipo se eligió la tarjeta DAQ NI USB-6008 [35].

C. Test Set-Up

Siguiendo las consideraciones comentadas en el apartado anterior, se han colocado un total de diez acelerómetros, distribuidos de la siguiente manera: dos acelerómetros en el generador, siete acelerómetros en la multiplicadora y un acelerómetro en el rodamiento del eje lento (Fig. 5).



Fig. 5. Distribución de los acelerómetros en el prototipo.

Las fallas y condiciones introducidas son:

- Rodamiento en buen estado
- Desequilibrio
- Rotura de la rodadura del rodamiento
- Exceso de grasa en el rodamiento

D. Data Set

Para cada condición, se probaron 2 rodamientos en diferentes condiciones, lo que resultó un total de 12 ejecuciones. Cada prueba tuvo una duración de 2 minutos desde la cual se capturaron los últimos 30 segundos de datos de vibración en el plano x e y usando los acelerómetros.

E. Simulación

Tal y como se ha comentado anteriormente, la forma tradicional de medir las vibraciones presentes en cualquier sistema es mediante un análisis espectral. En la Fig. 7, se observan los resultados de aplicar la metodología clásica de análisis espectral. En este caso se ha simulado un correcto funcionamiento. En dicha figura se observa la salida de los 10 acelerómetros distribuidos a lo largo de la maqueta del aerogenerador. Este prototipo puede ser programado en 5 diferentes velocidades de giro, comprendidas entre los 0 y 1500 rpm. En este caso se ha utilizado una velocidad moderada, correspondiente a los 300 rpm. Para la representación gráfica de cada uno de los sensores analizados, se ha empleado una frecuencia de muestreo de 1khz y en total se han obtenido unas 5000 muestras por cada sensor.

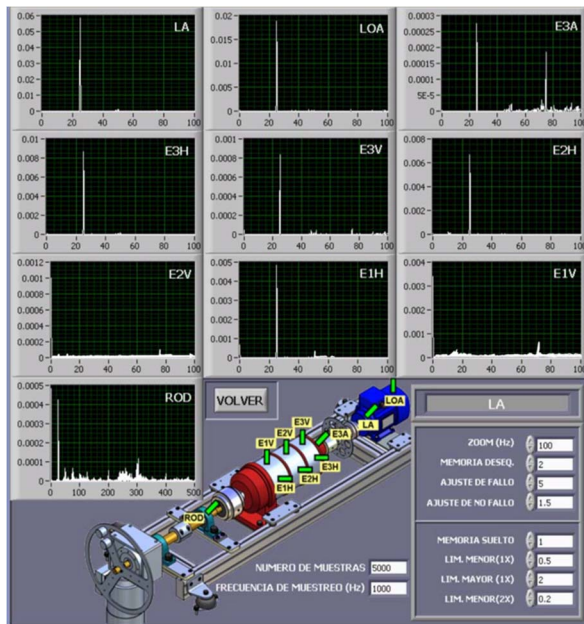


Fig. 7. Detección de las vibraciones del sistema.

El aumento de la tecnología está cambiando las metodologías clásicas de análisis de vibraciones, por técnicas más autónomas y precisas. La implementación de sistemas de aprendizaje automático, permiten una correcta supervisión, prevención y diagnóstico de fallos en aerogeneradores. Tal y como se ha especificado en apartados anteriormente, una de las bases principales para una correcta predicción automática, es enseñar al algoritmo y entrenarlo, para que obtenga un feedback, permitiendo a posteriori, su trabajo autónomo mediante el análisis y clasificación de los datos.

En total este algoritmo se ha entrenado unas 8 veces distintas, con lo que se considera una retroalimentación suficiente para su predicción. Dicho entrenamiento a consistido en simular los cuatro estados de análisis, es decir, un rodamiento en buen estado, un exceso de aceite o rotura del mismo y un desequilibrio.

En la Fig. 8, se puede observar una comparativa entre la salida real y la predecida para cada ambos clasificadores, el K-Nearest neighbour (KNN) y el Support Vector Machines (SVM). Su obtención, ha estado dividida en 4 fases. La primera consistió en la obtención de los datos sensados por medio de la tarjeta de adquisición PCI-4472B, para su posterior filtrado [36]. Tras ello, se realizó una extracción de características para obtener la media, el análisis de componentes principales y la desviación estándar de cada fallo o condición estipulada. Estas 3 primeras etapas son genéricas para ambos clasificadores. Tras el correcto acondicionamiento de los datos, en este punto es donde cada metodología de los dos algoritmos analizados entra en vigor, realizando una clasificación de los datos en cuestión. Tras ello, se repite todo este proceso varias veces con el fin de entrenar al algoritmo para su posterior autofuncionamiento.

Después de varios entrenamientos, el algoritmo ya esta listo para funcionar, únicamente necesita nuevos datos. Estos nuevos datos son analizados y clasificados con el fin de realizar una predicción del proceso a controlar en concreto.

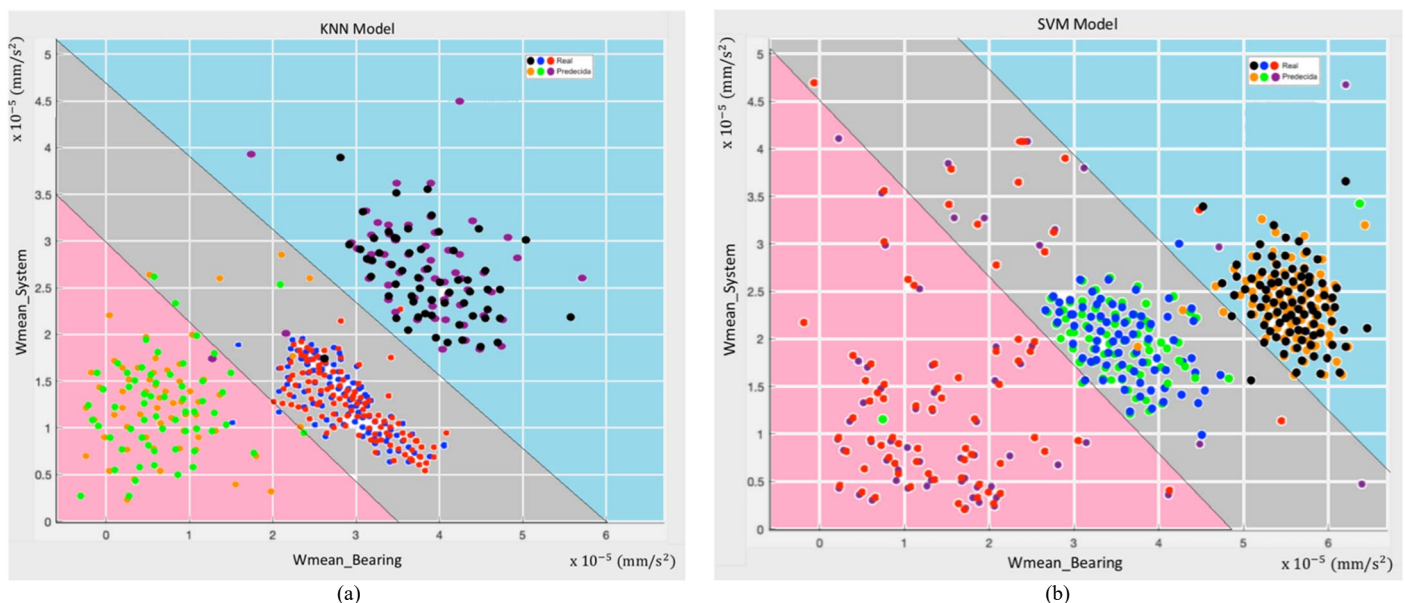


Fig. 8. (a) (KNN) K-Nearest neighbour (b) (SVM) Support Vector Machines.

En la Fig. 8 se observa una comparativa de los dos clasificadores implementados, representado en ellos una media de vibraciones de todo el sistema, obtenida a partir de los 10 acelerómetros distribuidos a lo largo del prototipo, contra la media de las diferentes lecturas del acelerómetro situado en el rodamiento del eje lento. Cada figura está dividida en 3 colores, los cuales representan cada uno de los fallos establecidos. La zona de color rosa, representa la zona de rotura de la pista de rodadura del rodamiento. La zona gris representa un desequilibrio del sistema, mientras que la azul, un exceso de grasa en el rodamiento.

Desglosemos cada una de estas zonas por separado. En la zona de fallo debido a desequilibrios (zona gris), podemos observar que los resultados son bastantes parejos para los dos algoritmos, ya que tanto la salida real como la predecida, presentan una gran similitud. Además, cabe destacar que todos los valores de lecturas se encuentran dentro de la zona acotada para desequilibrios, con lo que, para este caso, ambas metodologías funcionan a la perfección. En cuanto al fallo debido a la rotura de la pista de rodadura del rodamiento, (zona rosa), ambos algoritmos ya no se comportan de la misma manera. Los datos analizados para el KNN se encuentran más agrupados que los SVM, esto es debido que la diferente forma de clasificar y analizar los datos, debido a que no siguen un patrón determinado. Además, para el SVM los resultados son más dispersos, favoreciendo que gran parte de ellos, se encuentran fuera del rango determinado como rotura de rodamiento. Por último, se encuentra la zona azul, la cual representa un exceso de grasa en el rodamiento. Ambos clasificadores siguen más o menos el mismo patrón, pero en este caso, en el algoritmo KNN la zona determinada como exceso de grasa (zona azul) es más amplia que la del SVM, debido a los límites empleados para este caso.

Finalmente cabe destacar que, para cualquiera de las tres condiciones de fallos propuestas, ambos algoritmos predicen con gran exactitud la salida real con la predecida.

Comparando los resultados obtenidos de ambos clasificadores, se observa que los resultados no difieren mucho de un clasificador a otro. En la Fig. 9 se representa a la matriz de confusión. Su interpretación es muy sencilla, es decir todo lo que se encuentra en la diagonal ha sido clasificado

correctamente (verde), mientras que lo que no, fue clasificado erróneamente. Por ejemplo, centrémonos en la variable de desequilibrio. Un 91% de las veces esta variable es clasificada correctamente, mientras el otro 9% restante, el algoritmo se confunde la variable desequilibrio con la de exceso de aceite. Cabe destacar que la métrica de precisión (verdaderos positivos/falsos positivos) es muy positiva, debido a que los resultados verdaderos superan el 90%, mientras que los falsos son inferiores al 10%. Para el K-Nearest Neighbour (KNN) se ha obtenido un 94% de acierto, mientras que en el Support Vector Machines (SVM) un 95%. Por lo tanto, ambas metodologías de aprendizaje basadas en los algoritmos de KNN y el SVM, presentan bastante similitud con lo que se considera que estos algoritmos se adaptan y funcionan perfectamente en nuestro prototipo de aerogenerador, permitiéndonos poder predecir con gran exactitud los fallos en el prototipo.

IV. CONCLUSIONES

Los sistemas de aprendizaje automático están cambiando la forma de detectar, monitorizar y diagnosticar fallos en aerogenerador, haciéndolos más accesibles y robustos. Gran parte del éxito y correcto funcionamiento de la IA se basa en la adquisición y clasificación de los datos. En este documento, se han estudiado varias técnicas de IA para el diagnóstico y prevención de fallos en los rodamientos de un aerogenerador, mediante el análisis de vibraciones.

El diagnóstico de fallas para rodamientos basado en los modelos K-NN y en el SVM se ha resumido tanto desde el punto de vista teórico como desde el punto de vista práctico. Las principales ventajas que presentan estos dos modelos son muy variadas, debido a su alta velocidad de procesamiento, robustez y su precisión para este tipo de estudios es muy elevado. Algunas de estas ventajas, así como su facilidad de clasificación y predicción de la respuesta, está desbancando a las técnicas tradicionales, tales como el análisis espectral. En los resultados se han demostrado su gran acierto en la predicción de las condiciones de fallos estipuladas, permitiendo extrapolar esta metodología a otras partes mecánicas del prototipo, con el fin principal de prevenir o anticiparse a las posibles averías ocasionadas en los aerogeneradores.

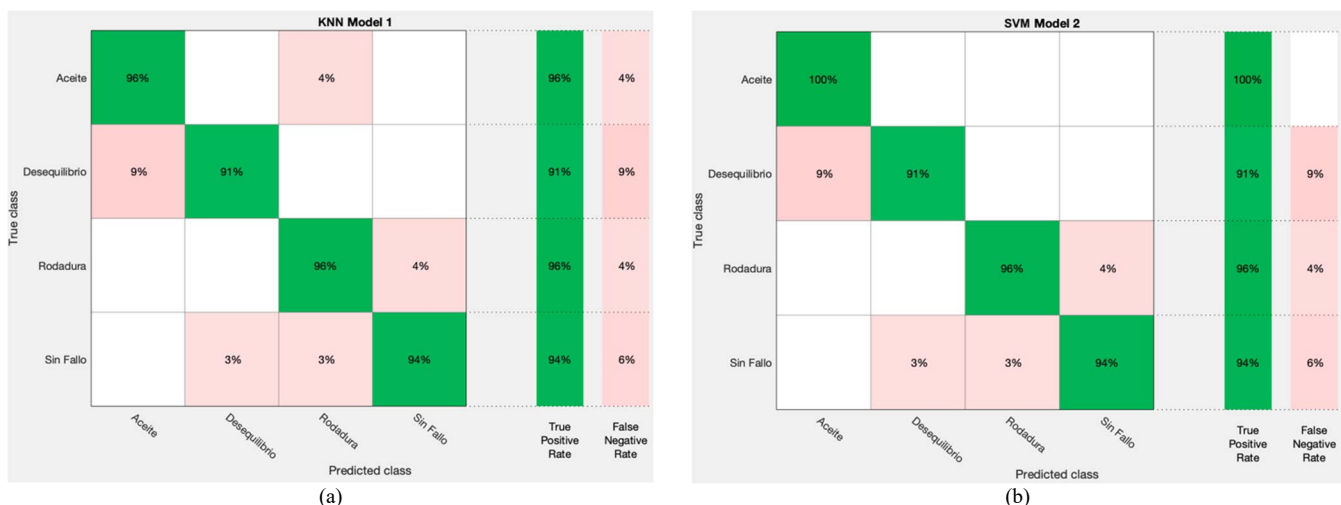


Fig. 9. (a) Confusion matrix (KNN) K-Nearest neighbour (b) Confusion matrix (SVM) Support Vector Machines.

El prototipo implementado proporciona la posibilidad de sustituir piezas por otras defectuosas o desgastadas y simular fallos típicos de aerogeneradores. Estas posibilidades de estudio facilitan el estudio, desarrollo y validación de nuevas técnicas de supervisión y diagnóstico de fallos.

La utilización del prototipo de aerogenerador es muy útil para comprobar algoritmos de diagnóstico diseñados, en la fase previa a su instalación en aerogeneradores de alta potencia, reduciendo costes y tiempo, permitiendo así verificarlos, ajustarlos y corregirlos si fuera necesario, haciéndolos más precisos y fiables.

REFERENCIAS

- [1] Risteiu, M., Todoran, R. M., & Todor, N. (2010). Designing Adaptive Control Management System for Small Wind Generators to Low Power Grid. *Annals of DAAAM & Proceedings*.
- [2] Le, B., & Andrews, J. (2016). Modelling wind turbine degradation and maintenance. *Wind Energy*, 19(4), 571-591.
- [3] Arcos Jiménez, A., Gómez Muñoz, C., & García Márquez, F. (2018). Machine learning for wind turbine blades maintenance management. *Energies*, 11(1), 13.
- [4] Igba, J., Alemzadeh, K., Henningsen, K., & Durugbo, C. (2015). Effect of preventive maintenance intervals on reliability and maintenance costs of wind turbine gearboxes. *Wind Energy*, 18(11), 2013-2024
- [5] Jonkman, J., Butterfield, S., Musial, W., & Scott, G. (2009). Definition of a 5-MW reference wind turbine for offshore system development. *National Renewable Energy Laboratory, Golden, CO, Technical Report No. NREL/TP-500-38060*.
- [6] Kusiak, A., & Zheng, H. (2010). Optimization of wind turbine energy and power factor with an evolutionary computation algorithm. *Energy*, 35(3), 1324-1332.
- [7] Andrawus, J. A., Watson, J., & Kishk, M. (2007). Wind turbine maintenance optimisation: principles of quantitative maintenance optimisation. *Wind Engineering*, 31(2), 101-110.
- [8] Barazarte, R. Y., Gonzalez, G., & Hall, E. (2011). Comparison of electrical generators used for wind power generation. *IEEE Latin America Transactions*, 9(7), 1040-1044.
- [9] Estupiñan, E. A., & Saavedra, P. N. (2010). Análisis de vibraciones aplicado a las máquinas rotatorias de baja velocidad. *El mantenimiento mundial*, 1-6.
- [10] Igba, J., Alemzadeh, K., Durugbo, C., & Eiriksson, E. T. (2016). Analysing RMS and peak values of vibration signals for condition monitoring of wind turbine gearboxes. *Renewable Energy*, 91, 90-106.
- [11] Elkasem, A. H., Kamel, S., Rashad, A., & Jurado, F. (2018, December). Optimal Performance of DFIG Integrated with Different Power System Areas Using Multi-Objective Genetic Algorithm. In *2018 Twentieth International Middle East Power Systems Conference (MEPCON)* (pp. 672-678). IEEE.
- [12] Yang, W., Tavner, P. J., Crabtree, C. J., Feng, Y., & Qiu, Y. (2014). Wind turbine condition monitoring: technical and commercial challenges. *Wind Energy*, 17(5), 673-693.
- [13] Yang, W., Court, R., & Jiang, J. (2013). Wind turbine condition monitoring by the approach of SCADA data analysis. *Renewable Energy*, 53, 365-376.
- [14] Lou, J., Jia, X. U., & Heng, L. U. (2016). "Wind turbine data-cleaning algorithm based on power curve. *Automation of Electric Power Systems*.
- [15] Sheng, S. (Ed.). (2014). Wind turbine condition monitoring. *Wind Energy*, 17(5), 671-672.
- [16] Márquez, F. P. G., Tobias, A. M., Pérez, J. M. P., & Papaelias, M. (2012). Condition monitoring of wind turbines: Techniques and methods. *Renewable Energy*, 46, 169-178.
- [17] Ibrahim, Y., Kamel, S., Rashad, A., Nasrat, L., & Jurado, F. (2019). Performance Enhancement of Wind Farms Using Tuned SSSC Based on Artificial Neural Network. *Int. J. Interact. Multimedia Artif. Intell*, 1, 1-7.
- [18] E.J. Terrell, W.M. Needelman, J.P. Kyle, Wind turbine tribology, in: M. Nosonovsky, B. Bhushan (Eds.), *Green Tribology*, Green Energy and Technology, Springer Berlin Heidelberg, 2012, pp. 483–530.
- [19] W.A. Smith, R.B. Randall, Rolling element bearing diagnostics using the case western reserve university data: a benchmark study, *Mechanical Systems and Signal Processing* 64-65 (2015) 100–131.
- [20] Boufounas, E. M., Koumir, M., & Boumhidi, I. (2016). Optimal intelligent control for a variable-speed wind turbine using general regression neural network and adaptive PSO algorithm. *International Journal of Intelligent Engineering Informatics*, 4(3-4), 267-285.
- [21] P. Bošković, J. Petrović, B. Musizza, Dani Juričić, Detection of lubrication starved bearings in electrical motors by means of vibration analysis, *Tribology International* 43 (9) (2010) 1683–1692.
- [22] Zhao, R., Yan, R., Chen, Z., Mao, K., Wang, P., & Gao, R. X. (2019). Deep learning and its applications to machine health monitoring. *Mechanical Systems and Signal Processing*, 115, 213-237.
- [23] Elkasem, A. H., Kamel, S., Rashad, A., & Melguizo, F. J. (2019). Optimal Performance of Doubly Fed Induction Generator Wind Farm Using Multi-Objective Genetic Algorithm. *IJIMAI*, 5(5), 48-53.
- [24] Abdel-Nasser, M., Mahmoud, K., & Kashef, H. (2018). A Novel Smart Grid State Estimation Method Based on Neural Networks. *IJIMAI*, 5(1), 92-100.
- [25] Janssens, O., Slavković, V., Vervisch, B., Stockman, K., Locuffier, M., Verstockt, S., ... & Van Hoecke, S. (2016). Convolutional neural network based fault detection for rotating machinery. *Journal of Sound and Vibration*, 377, 331-345.
- [26] Beşkirli, M., Koç, İ., Haklı, H., & Kodaz, H. (2018). A new optimization algorithm for solving wind turbine placement problem: Binary artificial algae algorithm. *Renewable energy*, 121, 301-308.
- [27] Chen, Y., & Hao, Y. (2017). A feature weighted support vector machine and K-nearest neighbor algorithm for stock market indices prediction. *Expert Systems with Applications*, 80, 340-355.
- [28] Rebolgar, A. M., Gomez, W. A. S., Garcia, R. A. B., Baldizon, Y. G., Lavalle, M. M., & Hernandez, J. O. (2018). A Job Stress Predictive Model Evaluation Through Classifier's Algorithms. *IEEE Latin America Transactions*, 16(1), 178-185.
- [29] Suthaharan, S. (2016). Support vector machine. In *Machine learning models and algorithms for big data classification* (pp. 207-235). Springer, Boston, MA.
- [30] Danades, A., Pratama, D., Anggraini, D., & Anggriani, D. (2016, October). Comparison of accuracy level K-nearest neighbor algorithm and support vector machine algorithm in classification water quality status. In *2016 6th International Conference on System Engineering and Technology (ICSET)* (pp. 137-141). IEEE.
- [31] Wen, W., & Durrant-Whyte, H. F. (1992, May). Model-based multi-sensor data fusion. In *Robotics and Automation, 1992. Proceedings., 1992 IEEE International Conference on* (pp. 1720-1726). IEEE.
- [32] Boufounas, E. M., Koumir, M., & Boumhidi, I. (2016). Optimal intelligent control for a variable-speed wind turbine using general regression neural network and adaptive PSO algorithm. *International Journal of Intelligent Engineering Informatics*, 4(3-4), 267-285.
- [33] Márquez, F. P. G., Tobias, A. M., Pérez, J. M. P., & Papaelias, M. (2012). Condition monitoring of wind turbines: Techniques and methods. *Renewable Energy*, 46, 169-178.
- [34] Gao, X., Yang, H., Lin, L., & Koo, P. (2015). Wind turbine layout optimization using multi-population genetic algorithm and a case study in Hong Kong offshore. *Journal of Wind Engineering and Industrial Aerodynamics*, 139, 89-99.
- [35] Módulo de muestreo. National Instruments. Disponible: <http://www.ni.com/pdf/manuals/371747f.pdf>. Mayo 2018
- [36] Paez Galice, A. Mantenimiento predictivo en aerogeneradores: análisis de vibraciones. *Universitat Politècnica de Catalunya*, Enero 2018.



Javier Vives graduated in Electronic and Mechanical Engineering. In 2016 he obtained a Master's Degree in Automation and Industrial Computing from Universitat Politècnica de València, where he currently is a PhD student in Automation, Robotics and Industrial Computer Science. His current research areas are fault detection and diagnosis and systems reliability.



Eduardo Quiles received an M.Sc in Electrical Engineering from Universitat Politècnica de València in 1993, and a Ph.D. from the same university in 1998. In 1996 he joined the Systems and Control Engineering Department in Universitat Politècnica de València, where he is associate professor. His current research areas are fault detection and diagnosis and systems reliability.



Emilio García received a degree in electronics in the Faculty of Physics of University of Valencia in 1995. He obtained his Ph.D. degree from Universitat Politècnica de València in 2000. Since 1989 he has been with the Department of Systems Engineering and Control in Universitat Politècnica de València as an associate professor. His research interests are in discrete-event and hybrid systems.