

ARQUITECTURA PARA SISTEMA DE MONITOREO BASADO EN CONDICIONES CON ALMACENAMIENTO EN LA NUBE

Yarens J. Cruz Hernández, Alberto Villalonga Jaén

*° Centro de Estudios para la Fabricación Avanzada y Sostenible (CEFAS). Universidad de Matanzas
Autopista a Varadero 3½, Matanzas 44740, Cuba.*

Teléf.: +(53) 45256812, Web: <http://cefes.umcc.cu>, Email: yarens.cruz@umcc.cu, alberto.villalonga@umcc.cu

Resumen: En la industria moderna se están incorporando nuevos paradigmas que permiten desarrollar e implementar sistemas más confiables y eficientes. Unos de los sistemas que más se han beneficiado con estos paradigmas son los de monitoreo y control; sin embargo, no todas las organizaciones cuentan con el capital necesario para adoptar estos cambios debido al alto precio en el mercado de las herramientas necesarias. En este trabajo se propone la arquitectura de un sistema de monitoreo para la detección de fallas en maquinarias de procesos de manufactura. La arquitectura propuesta se enfoca en el Monitoreo Basado en Condiciones mediante el análisis de las señales de vibración en el dominio del tiempo y utiliza técnicas de Inteligencia Artificial; además de permitir el almacenamiento de datos en la nube, obteniéndose de esta manera la arquitectura de un sistema de monitoreo acorde a la Industria 4.0.

Palabras claves: Industria 4.0; Monitoreo Basado en Condiciones; Inteligencia Artificial; Detección de Fallas

Abstract: New paradigms that allow the development and implementation of more reliable and efficient systems are being incorporated in modern industry. Some of the systems that have benefitted the most of these paradigms are monitoring and control systems; however, not all the enterprises have enough capital to adopt these changes due to the high prices of the necessary tools in the market. The architecture of a monitoring system for fault detection in manufacturing processes is presented in this work. The proposed architecture is focus on Condition-Based Monitoring by means of the analysis of vibration signals in time domain. The system also uses Artificial Intelligence techniques and allows data storage on the cloud, obtaining as a result the architecture of a monitoring system according to Industry 4.0.

Keywords: Industry 4.0; Condition-Based Monitoring, Artificial Intelligence; Fault Detection

1. Introducción.

En la industria moderna se han comenzado a introducir una serie de tecnologías, tales como la Inteligencia Artificial (IA), los Sistemas Ciberfísicos (SCF), la computación en la nube y la Internet de las cosas, entre otros, que han dado paso a una serie de transformaciones en las relaciones de producción. Estos cambios han producido notables beneficios entre los que se pueden destacar el desarrollo tecnológico, la flexibilidad en la producción, la personalización de los productos, la optimización de la toma de decisiones y el aumento de la productividad y la

eficiencia en la utilización de los recursos. Constituye, por tanto, una necesidad para las industrias de nuestro país el desarrollo de sistemas que permitan adoptar estos nuevos paradigmas y den paso al salto cualitativo indispensable para estar acorde a la industria moderna.

Una de las áreas donde más han impactado estas nuevas tecnologías ha sido en la detección de fallas industriales. Debido al aumento del número de procesos de manufactura en nuestro país para sustituir importaciones y al alto nivel de explotación de las maquinarias, se hace imprescindible contar con sistemas más precisos de detección de fallas que permitan evitar malfuncionamientos y accidentes. Por lo antes expuesto, este trabajo tiene como objetivo el diseño de la arquitectura de un sistema de detección de fallas que incorpore paradigmas de la Industria 4.0 para mejorar su rendimiento.

2. Materiales y métodos.

El monitoreo basado en condiciones (condition-based monitoring, CM) es el proceso mediante el cual se determina el estado operacional y la salud de una máquina con el propósito de detectar fallas potenciales antes de que se conviertan en fallas funcionales. El CM consiste en el almacenamiento periódico o continuo de colecciones de datos, su análisis, interpretación y diagnóstico [1]. Este tipo de monitoreo ha probado ser efectivo, permitiendo aumentar la seguridad, la rentabilidad y la competitividad, por lo que está asumiendo un papel cada vez más importante en la industria [2].

Al igual que un doctor recomienda a su paciente chequeos de rutina periódicos de algunos parámetros claves para la salud como son la presión sanguínea, el pulso, el peso y la temperatura para poder detectar a tiempo problemas potenciales de salud, se pueden medir ciertos parámetros de los equipos industriales para evaluar su estado [3]. En sectores industriales, las aplicaciones de CM más reportadas se centran en: análisis y diagnóstico de vibraciones; análisis de lubricantes; análisis de emisiones acústicas; termografía infrarroja; pruebas de ultrasonido, análisis del estado del motor y el consumo, entre otros [4-5].

El análisis de vibraciones se puede realizar tanto on-line como off-line y se utiliza para detectar funcionamientos defectuosos del sistema basado en la medición de las señales de vibración [3]. Una gran variedad de enfoques se han presentado para el análisis de estas señales, los cuales pueden ser clasificados en: análisis en el dominio del tiempo, en el dominio de la frecuencia y en el dominio tiempo-frecuencia. También han sido aplicadas al análisis de vibraciones diversas técnicas de Inteligencia Artificial (IA) para el modelado como son las Redes Neuronales Artificiales (RNA) y los sistemas difusos [6-9]. Todas estas técnicas, aunque cada una con sus particularidades, parten de la misma idea básica: determinar cuáles son las características de la señal cuando la máquina se encuentra funcionando correctamente, para que, al detectar cambios en estas características, indicar un posible fallo. El análisis de vibraciones es una de las técnicas de CM más difundida en la industria debido a que el 90% de los fallos industriales viene precedido por cambios en esta señal.

Para realizar el análisis de vibraciones en Controles Numéricos Computarizados (CNC) con el objetivo de detectar fallas potenciales se propone la arquitectura de la Fig. 1, en la cual las señales

de vibración provienen de acelerómetros que se deben instalar cerca de las partes móviles del CNC, en caso de que estos no vengán integrados en su fabricación.

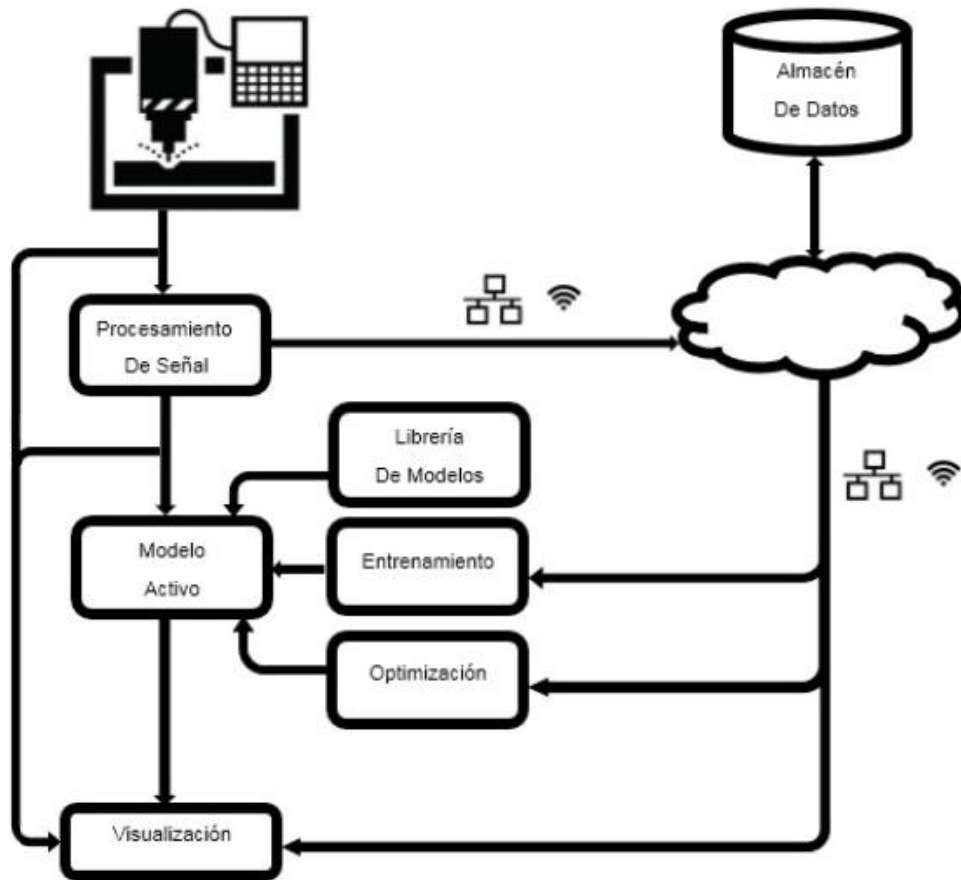


Figura 1. Propuesta de la arquitectura del sistema.

El módulo que recibe la señal de vibraciones directamente es el módulo de procesamiento de la señal. La señal de vibraciones al ser medida contiene mucho ruido asociado, por lo que, antes de extraer sus principales características o realizar cualquier análisis con ella, este ruido debe ser eliminado. Para lograr la eliminación del ruido se utiliza un filtro pasa alto. Luego de haber suprimido el ruido de la señal se pasa a determinar los valores de las características que serán utilizadas para el CM. Para el análisis de la señal de vibraciones en el dominio del tiempo se proponen utilizar los estadígrafos valor de pico (V_p), promedio (μ), desviación estándar (σ), raíz cuadrática media (RCM), factor de cresta (F_{cr}), factor de claridad (F_{cl}), factor de impulso (F_i), factor de forma (F_f), *distorsión* y *curtosis*, los cuales se calculan de acuerdo a las siguientes ecuaciones:

$$V_p = \frac{1}{2} [\max(x_i) - \min(x_i)] \quad (1)$$

$$\mu = \frac{1}{N} \sum_{i=1}^N x_i \quad (2)$$

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2} \quad (3)$$

$$RCM = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i)^2} \quad (4)$$

$$F_{cr} = \frac{V_p}{RCM} \quad (5)$$

$$F_{cl} = \frac{V_p}{\left(\frac{1}{N} \sum_{i=1}^N \sqrt{|x_i|}\right)^2} \quad (6)$$

$$F_i = \frac{V_p}{\frac{1}{N} \sum_{i=1}^N |x_i|} \quad (7)$$

$$F_f = \frac{RCM}{\frac{1}{N} \sum_{i=1}^N |x_i|} \quad (8)$$

$$distorsión = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^3}{\sigma^3} \quad (9)$$

$$curtosis = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^4}{\sigma^4} \quad (10)$$

Una vez que se tienen los valores de las principales características de la señal de vibraciones, estos se almacenan en la nube y, al mismo tiempo, se seleccionan los que se pasarán al módulo en el cual se realizará el monitoreo de los mismos. El hecho de tener los datos almacenados en la nube, en los llamados almacenes de datos, permite que estos puedan ser accedidos desde cualquier lugar y en cualquier momento, siempre que se cuente con una conexión a Internet. Además, debido a la gran cantidad de información que se debe registrar es más rentable almacenarla en Internet que en servidores propios. El aumento en el costo de los centros de almacenamiento de datos no está dado por un incremento en el precio del hardware, sino de la demanda energética para su correcto funcionamiento [10]. Al utilizar el almacenamiento en la

nube la responsabilidad de la gestión energética pasa al proveedor del servicio de almacenamiento.

Por otra parte, en la librería de modelos se encuentran los modelos de IA que pueden ser utilizados para realizar el diagnóstico de los CNC. Aquí los modelos se encuentran en una forma genérica y sin parametrizar, ya que estos deben poder adaptarse a los requerimientos específicos de cada CNC. Inicialmente se prevé la inclusión de dos tipos de modelos en la librería; uno basado en un Sistema de Inferencia Difuso Takagi-Sugeno-Kang (TSK) y el otro basado en una Red Neuronal Artificial (RNA) de tipo Perceptrón Multicapa, pero se deja abierta la posibilidad de agregar más modelos de IA, ya sean basados en RNA, lógica difusa u otras técnicas que sean efectivas para el CM.

Los Sistemas de Inferencia Difusos TSK presentan como principal particularidad que no requieren un desborrosificador, ya que el valor de la variable de salida calculado en cada regla no es un dato difuso, sino que es preciso. Esto es posible ya que el consecuente de cada regla se plantea en forma de una función lineal que depende de las variables de entrada. La k -ésima regla en un Sistema de Inferencia Difuso TSK tiene la siguiente forma:

Si x_1 es Q_{1k} y x_2 es Q_{2k} y ... y x_n es Q_{nk} ,

$$\text{Entonces } z = p_0^k + p_1^k x_1 + p_2^k x_2 + \dots + p_n^k x_n$$

Para calcular el valor de la variable de salida del sistema difuso TSK se utiliza la siguiente ecuación:

$$y = \frac{\sum_{i=1}^M w_i z_i}{\sum_{i=1}^M w_i} \quad (11)$$

Donde: M es el número de reglas difusas; w_i es el coeficiente de ponderación calculado para la i -ésima regla; y z es la consecuencia de la i -ésima regla.

Por su parte, las RNA Perceptrón Multicapa son un tipo de modelo de red neuronal de avance hacia adelante, es decir, donde las conexiones entre las capas se realizan en una sola dirección. Estas redes están compuestas generalmente de tres o más capas de neuronas, donde todas las neuronas artificiales son de tipo Perceptrón y la salida de cada neurona se calcula utilizando la siguiente ecuación:

$$y = \sigma\left(\sum_{i=1}^n W_i U_i + b\right) \quad (12)$$

Donde: U_i denota las entradas, b denota un valor de sesgo y W_i denota los pesos de los coeficientes sinápticos, siendo la sinapsis una unión intercelular especializada entre neuronas y σ una función de activación no lineal.

Los perceptrones pueden ser considerados como los modelos más simples de neuronas artificiales debido a su función de activación, la cual es una función de paso discontinuo unipolar. La convolución de este tipo de red se puede cambiar variando el número de capas y el número de unidades en cada capa. Se ha demostrado que una RNA Perceptrón Multicapa se puede adaptar para estimar aproximadamente cualquier función con la precisión deseada [11].

El entrenamiento o aprendizaje es el proceso mediante el cual se ajustan los parámetros de un modelo de IA para que este sea capaz de reproducir, con una precisión aceptable, una relación entre los datos de entrada y los de salida. Entre las diversas técnicas de entrenamiento que existen, una de las más utilizadas es el supervisado. En este tipo de entrenamiento se utiliza un conjunto de datos de entrada y otro conjunto de datos que representa la salida que se desea produzca el sistema. Los valores de los parámetros del modelo se varían de acuerdo a alguna estrategia que permita que las salidas reales que produzca el sistema sean razonablemente similares a las salidas deseadas. El módulo de entrenamiento permite acceder a los datos históricos del CNC que se tengan almacenados, los cuales deben reflejar tanto la operación de la máquina en estado normal, así como funcionamientos defectuosos, para que el modelo a entrenar pueda clasificar ambos estados.

En el caso del Sistema Difuso TSK, el entrenamiento consiste en la construcción de la base de reglas. Por la dificultad de dicho proceso se propone utilizar un método automático de generación de reglas. Dicho método debe ser capaz de definir los antecedentes de las reglas mediante una técnica de agrupamiento como es el Agrupamiento Sustractivo y los consecuentes mediante el algoritmo de estimación de Mínimos Cuadrados.

Para el entrenamiento de las RNA Perceptrón Multicapa el método propuesto es la retropropagación de errores. En la retropropagación de errores se calcula la pendiente de una función de pérdida con referencia a todos los pesos en el modelo de red y se equilibran los pesos mediante el gradiente descendiente, en un intento de minimizar la función de error [12].

Una vez que los modelos han sido entrenados, estos ya se pueden utilizar para realizar el CM. Sin embargo, no se puede asegurar que los valores asignados a los parámetros requeridos para definir el modelo o entrenarlo hayan sido los más idóneos; es por esta razón que se propone antes de usar los modelos, aplicarles alguna técnica de optimización para la parametrización.

Para realizar la optimización se propone utilizar el método de la Entropía Cruzada, el cual fue presentado como un algoritmo de aprendizaje estocástico para la estimación de la probabilidad de eventos aislados. Su uso ha sido expandido como una herramienta genérica y eficiente para resolver problemas numéricos de gran dificultad y problemas de optimización combinatoria NP-Hard.

Anteriormente se propusieron los modelos de la librería, los métodos de entrenamiento para ellos y además las técnicas de optimización; sin embargo, todos los modelos no se pueden utilizar simultáneamente para realizar el CM, sino que se debe escoger uno. Una vez que se haya seleccionado el modelo y se haya parametrizado correctamente para adaptarlo al CNC sobre el

que va a actuar, ya se puede activar el modelo, es decir, ya se pueden recibir los datos del módulo de procesamiento de señal para realizar el diagnóstico.

Finalmente, se propone un módulo de visualización el cual recibirá datos de varias fuentes, lo que permite conocer la información que se está procesando y transmitiendo en cada módulo del sistema, en cada momento. Mediante la arquitectura propuesta se pueden observar los valores de la señal de vibraciones al ser medida o después de haber sido procesada y que se hayan determinado los valores de sus principales características. Por otra parte, también se puede conocer el diagnóstico emitido por el módulo donde se realiza el CM. En caso de detectarse una posible falla, esta información sería mostrada mediante una advertencia o alarma y las particularidades se podrían conocer a través del módulo de visualización.

El módulo de visualización también permite mostrar los datos almacenados en la nube, de manera que el operador puede tener acceso a todos los registros históricos que se hayan hecho del equipo. Por otra parte, el módulo de visualización también puede vincularse a algún software ofrecido como servicio en la nube, ya que existen, por ejemplo, aplicaciones en la nube para el monitoreo de información y la construcción de gráficos, como es el caso de Grafana, Power BI, Pentaho, Past3, entre otros.

3. Análisis de los resultados.

Para validar las técnicas que se utilizarán para el CM, las cuales forman parte de la propuesta de la arquitectura, se realizaron pruebas de caja negra a los modelos de IA. Las señales de vibración utilizadas fueron seleccionadas de un estudio realizado por el Centro de Inteligencia Sistemas de mantenimiento (IMS), Universidad de Cincinnati [13]. El conjunto de datos experimentales se generó a partir de ensayos de fallas en condiciones de carga constante en una plataforma de prueba. El eje fue accionado por un motor de corriente alterna acoplado por correas. La velocidad de rotación se mantuvo constante a 2000 rpm. Se agregó una carga radial de 6000 libras al eje y. Las vibraciones medidas fueron las generadas por cuatro rodamientos Rexnord ZA-2115 y se captaron con acelerómetros de alta sensibilidad. La frecuencia de muestreo fue de 20 kHz y la longitud de la señal de 20480 valores por muestra.

Se realizó el análisis de la señal de vibración del tercer rodamiento, el cual, luego de 30 días de trabajo presentó una falla en la pista interna. Se tuvieron en cuenta los estadígrafos valor de pico y raíz cuadrática media. Para la selección de los conjuntos de entrenamiento y validación se utilizó el método hold-out, tomándose para el entrenamiento el 67% de las muestras y el 33% para la validación. Como salidas del modelo se prefijaron los valores 0 (indicando buen estado del rodamiento) y 1 (indicando fallas en el rodamiento).

En las Fig. 2 y 3 se muestran los gráficos obtenidos para la validación de los dos modelos de IA después del entrenamiento, mientras que en la Tabla 1 se muestran los índices de desempeño: verdaderos positivos (VP), falsos positivos (FP), verdaderos negativos (VN), falsos negativos (FN), tasa de acierto (TA), especificidad (E) y sensibilidad (S).




Figura 2. Comportamiento del sistema difuso antes de la optimización.




Figura 3. Comportamiento de la red neuronal antes de la optimización.

Tabla 1. Índices de desempeño de los modelos antes de la optimización.

<i>Modelo</i>	<i>VP</i>	<i>FP</i>	<i>VN</i>	<i>FN</i>	<i>TA</i>	<i>E</i>	<i>S</i>
Sistema difuso TSK	168	58	443	31	87.5%	0.899	0.798
RNA Perceptrón Multicapa	183	71	430	16	88.1%	0.877	0.896

Posteriormente se procedió a optimizar los modelos. En las Fig. 4 y 5 se muestran los gráficos obtenidos para la validación de los modelos después de la optimización y, en la Tabla 2, los índices de desempeño.

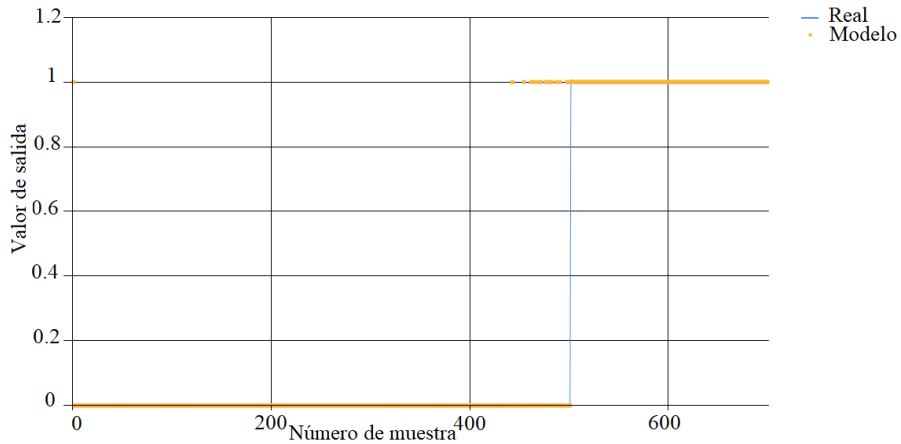


Figura 4. Comportamiento del sistema difuso después de la optimización.




Figura 5. Comportamiento de la red neuronal después de la optimización.

Tabla 2. Índices de desempeño de los modelos después de la optimización.

<i>Modelo</i>	<i>VP</i>	<i>FP</i>	<i>VN</i>	<i>FN</i>	<i>TA</i>	<i>E</i>	<i>S</i>
Sistema difuso TSK	199	16	485	0	97.7%	0.968	1.0
RNA Perceptrón Multicapa	199	11	490	0	98.4%	0.978	1.0

Al llevarse a cabo la optimización se aumentaron notablemente los valores de los índices de desempeño de los modelos, lográndose tasas de acierto muy elevadas y reduciéndose a cero los falsos negativos. Cabe destacar que los falsos positivos se concentraron antes de la ocurrencia del fallo, lo que permite detectar fallos potenciales, que es precisamente el objetivo del sistema.

4. Conclusiones.

Se presentó el diseño de la arquitectura para un sistema de CM para la detección de fallas con almacenamiento en la nube. La arquitectura se basa en el análisis de la señal de vibraciones en el dominio del tiempo mediante técnicas de IA. En el caso de estudio analizado se demostró la utilidad de la técnica de optimización propuesta y se corroboró que los algoritmos utilizados

permiten detectar fallas de manera temprana, lo que permite realizar el mantenimiento predictivo de los equipos de manufactura y evitar accidentes.

Referencias.

- [1] Y.-H. Kim, A. C. C. Tan, J. Mathew, and B.-S. Yang, "Condition Monitoring of Low Speed Bearings: A Comparative Study of the Ultrasound Technique Versus Vibration Measurements," in *Engineering Asset Management*, London, 2006, pp. 182-191.
- [2] T. Liu, J. Lemeire, F. Cartella, and S. Meganck, "An improved segmentation-based HMM learning method for Condition-based Maintenance," *Journal of Physics: Conference Series*, vol. 364, 2012.
- [3] W. Wang, "Condition-based Maintenance Modelling," in *Complex System Maintenance Handbook*, K. A. H. Kobbacy and D. N. P. Murthy, Eds., ed London: Springer London, 2008, pp. 111-131.
- [4] R. Ajith, A. Tewari, and D. Gupta, "Low-Cost Vibration Sensor for Condition-Based Monitoring Manufactured From Polyurethane Foam", *IEEE Sensors Letters*, vol. 1, pp. 1-4, 2017.
- [5] N. K. Verma, R. K. Sevakula, and R. Thirukovalluru, "Pattern Analysis Framework with Graphical Indices for Condition-Based Monitoring", *IEEE Transactions on Reliability*, vol. 66, pp. 1085-1100, 2017.
- [6] B. A. Paya, I. Esat, and M. Badi, "Artificial Neural Network Based Fault Diagnostics of Rotating Machinery Using Wavelet Transforms as a Preprocessor", *Mechanical Systems and Signal Processing*, vol. 11, pp. 751-765, 1997.
- [7] B. Li, M.-Y. Chow, Y. Tipsuwan, and J. C. Hung, "Neural-Network_Based Motor Rolling Bearing Fault Diagnosis", *IEEE Transactions on Industrial Electronics*, vol. 47, pp. 1060-1069, 2000.
- [8] C. K. Mechefske, "Objective machinery fault diagnosis using fuzzy logic", *Mechanical Systems and Signal Processing*, vol. 12, pp. 855-862, 1998.
- [9] M. Subrahmanyam and C. Sujatha, "Using neural networks for the diagnosis of localized defects in ball bearings", *Tribology International*, vol. 30, pp. 739-752, 1997.
- [10] K. Hwang, *Cloud Computing for Machine Learning and Cognitive Applications*. Massachusetts: The MIT Press, 2017.
- [11] R. C. Deo and M. Biazar, "Multi-layer perceptron hybrid model integrated with the firefly optimizer algorithm for windspeed prediction of target site using a limited set of neighboring reference station data", *Renewable Energy*, vol. 116, pp. 309-323, 2018.
- [12] A. Villalonga, R. Quiza, and Y. J. Cruz, "Módulo de monitoreo basado en estados para sistema inteligente de supervisión de procesos mecánicos", presented at the *19 Convención Científica de Ingeniería y Arquitectura*, 2018.
- [13] J. Lee, H. Qiu, G. Yu, and J. Lin, "Bearing Data Set", U. o. C. IMS, Ed., ed: NASA Ames Prognostics Data Repository, 2007.