



2019 10 al 13 de septiembre - Cartagena de Indias, Colombia

RETOS EN LA FORMACIÓN  
DE INGENIEROS EN LA  
ERA DIGITAL

# CLASIFICADORES ESTADÍSTICOS E INTELIGENCIA ARTIFICIAL COMO SOPORTE AL PROCESO DE APRENDIZAJE DEL MANTENIMIENTO BASADO EN LA CONDICIÓN

**Héctor Cardona, Yonny Valencia, Esteban Jiménez**

**Servicio Nacional de Aprendizaje SENA  
Rionegro Antioquia**

## Resumen

El presente artículo presenta una metodología de incorporación de los conceptos de mantenimiento predictivo y por condición de máquinas eléctricas rotativas de baja tensión mediante análisis de vibración y la implementación de algoritmos de inteligencia artificial con aprendizaje supervisado y no supervisado. Esta metodología es utilizada en las aulas de mantenimiento industrial del centro de la Innovación, Agroindustria y la Aviación del SENA con los aprendices de dichas áreas y ha logrado permear el entendimiento de sistemas complejos a partir del apoyo de clasificadores estadísticos basados en datos. La metodología propuesta comprende la fundamentación de los procesos y procedimientos de medición de vibraciones, la interpretación de las señales y su correspondiente normativa. Posteriormente, se implementan clasificadores estadísticos mediante herramientas computacionales libres (WEKA) donde se identifican correlaciones entre las diferentes variables. En este punto se retoman los procesos de modelado fenomenológico y se asocian dichas correlaciones estadísticas a fundamentaciones físicas. Finalmente, se entrenan diferentes escenarios de falla controladas y no controladas para determinar nuevas clasificaciones estadísticas. La metodología ha permitido avanzar rápidamente en la interpretación de escenarios de falla típicos a partir de mediciones en diferentes puntos de la máquina eléctrica, transmitiendo las herramientas de diagnóstico básico a los aprendices, además de la inmersión en el desarrollo y entrenamiento de sistemas expertos. Una de las ventajas identificadas mediante el presente proceso es la asociación fenomenológica de los eventos y correlaciones estadísticas, lo que permite concientizar técnicamente de los fenómenos eléctrico-mecánicos involucrados en las maquinarias bajo estudio.

**Palabras clave:** mantenimiento basado en la condición; clusterización; árboles de decisión

## **Abstract**

*This paper presents a methodology for the acquisition of condition based on predictive maintenance of low tension rotating electric machines by analyzing non-intrusive vibration signals and unsupervised and supervised artificial intelligence algorithms. This methodology is used in the classes of industrial maintenance at the Centro de la Innovación, Agroindustria y la Aviación del SENA as it helps to the students to understand complex systems supported in statistical classifiers based on experimental data. The proposed methodology includes the background of vibration measurements, signal interpretation and current standards. Afterwards, statistical classifiers are implemented through open-source software such as WEKA where correlations between acquired variables are identified. At this point, phenomenological modeling is used to associate the correlations that were found statistically. This methodology has helped to go further in the analysis of typical faults scenarios from experimental data points, training the students in the basics of vibration concepts and getting familiar with development and implementation of artificial intelligence. One of the advantages identified in the current process is the correlation of phenomenological basis of the experimental set-ups and the statistical results from data analysis, which turns into a deeper understanding of the electro-mechanical phenomena involved in the process under study.*

**Keywords:** *condition based maintenance; clustering; decision trees*

## **1. Introducción**

La inteligencia artificial(Lozano, 2007) ha jugado un papel fundamental en el entrenamiento de máquinas y sistemas expertos de los diferentes campos de la ingeniería, facilitando los procesos de diagnóstico y operación de sistemas complejos(QUINTANAR, 2007). En particular desde la adopción de procesos de mantenimiento predictivo en los elementos de las líneas de producción, la inteligencia artificial se ha convertido en una herramienta importante para la determinación de las condiciones de operación de sistemas y máquinas complejas. Hoy en día la inteligencia artificial fundamenta la tendencia del mantenimiento basado en la condición (Candanedo, González, & Muñoz, 2018). Y, a partir del desarrollo acelerado de los sistemas de instrumentación, la aparición de sensórica de bajo costo y los sistemas de procesamiento distribuido, se ha facilitado su aplicación a la industria y se está convirtiendo en un requerimiento dentro de las estrategias de mantenimiento y caracterización de elementos críticos dentro de las cadenas de valor y producción industrial dado que cada vez toma mayor importancia para el mantenimiento industrial la capacidad de establecer con mejor precisión el momento de una intervención de mantenimiento, así como la rápida caracterización, ubicación de la falla, consecuencias y costos de esta; con el fin de valorar de forma más precisa esa afectación. Lo anterior implica la implementación de herramientas tecnológicas y metodológicas adecuadas dentro de los procesos de mantenimiento (Candanedo et al., 2018), con la consiguiente cualificación del personal a cargo de esta área, que tendrá que ir adoptando paulatinamente los conocimientos necesarios (Laverde, 2016). Con esto, los formadores en el área del mantenimiento industrial, deberán actualizar los contenidos de los programas y considerar metodologías de enseñanza-aprendizaje consecuentes con el alcance y capacidades requeridas.

Para la implementación de la metodología se consideran grupos de aprendices diversos en edades conocimientos y experiencia, que incorporan nuevas competencias transversales como estrategia pedagógica (Sepúlveda, 2017). La metodología incluye conceptos y herramientas en mantenimiento predictivo, big data, machine learnig, inteligencia artificial, clasificadores estadísticos y a través de metodologías didácticas de estudios de caso, se incorporan estos nuevos conceptos y aplicaciones.

## **2. Mantenimiento basado en la condición y las estrategias de inteligencia artificial**

Para la determinación de la condición de la máquina y el estado de las variables de mantenimiento se establece un estado inicial de la máquina y la incorporación controlada de una falla conocida, para nuestro caso un desbalanceo con pesos de masas conocidas. En el caso del mantenimiento predictivo las vibraciones presentan una de las variables físicas más efectivas para llevar a cabo este proceso (White, 2010.), por medio de la obtención de estas variables en las máquinas bajo análisis, se pueden construir bases de datos asociadas a la operación de la máquina, de manera que se puedan establecer los patrones asociados a las condiciones normales de operación y a los cambios históricos de las misma, con esto, identificar las regiones de evolución de falla y nuevos métodos de falla que permiten elaborar herramientas predictivas para la detección de fallas incipientes.

En la metodología implementada se requiere como primer paso de análisis la identificación de la frecuencia fundamental y la elaboración de los espectros normalizados. Esta primera etapa permite la identificación de las fuerzas involucradas dentro del fenómeno vibratorio.

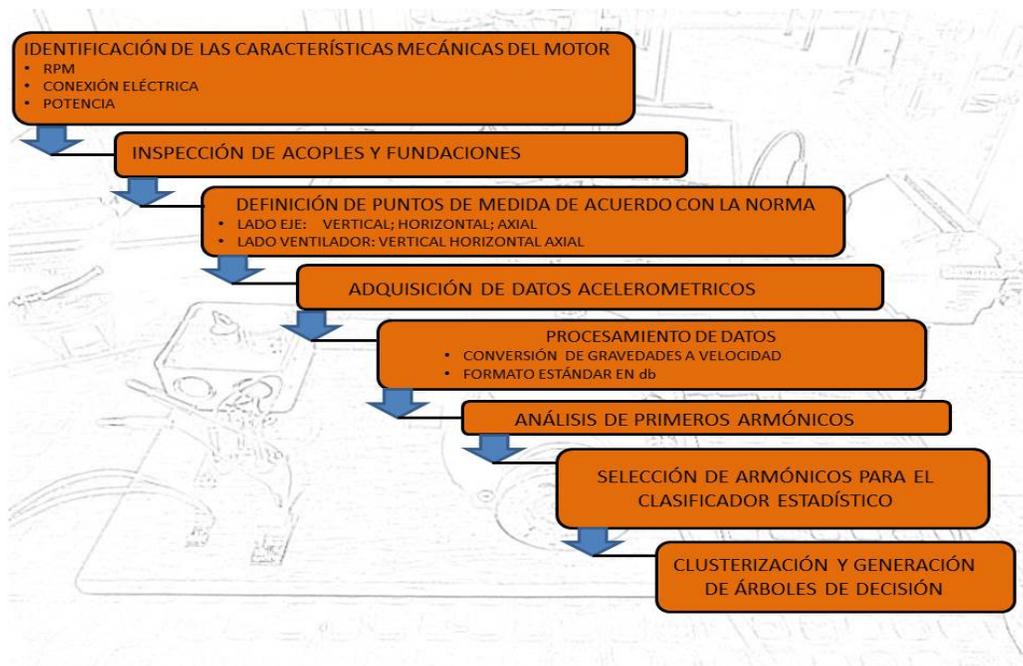


Fig. 1 Descripción de la metodología utilizada

Este procedimiento permite establecer los comportamientos del estado base de la maquinaria bajo análisis. La tendencia en los niveles de vibración para cada una de las frecuencias analizadas permite la identificación de los mecanismos que causan la aparición o el incremento de las frecuencias medidas. El caso fundamental de análisis es la condición de desbalanceo, en la cual la frecuencia normalizada 1X indica la severidad del desbalance (Mais, 2002). La existencia de armónicos asociados a la frecuencia normalizada indicará dentro del proceso la existencia de otros daños tales como: base de anclaje sueltos, ruptura de partes, entre otros (William R. Finley, Mark M. Hodowanec, 2000). Posterior al proceso de identificación de las frecuencias normalizadas que mejor representan las fallas a caracterizar, se hace uso de las herramientas estadísticas de clasificación para la definición de modelos de predicción basado en los datos experimentales obtenidos. Se han desarrollado numerosas estrategias estadísticas para la determinación de las condiciones de falla de máquinas (Ciabattini, Ferracuti, Freddi, & Monteriu, 2018; Widodo & Yang, 2007). Para la metodología desarrollada se utiliza el árbol de decisión como herramienta de clasificación (Quinlan, 2004), a partir de las frecuencias normalizadas que presenten una mayor sensibilidad a los desbalances inducidos.

### 3. Desarrollo de la metodología

Las mediciones llevadas a cabo dentro del proceso metodológico implementado consistieron en la ubicación de 4 acelerómetros al sistema bajo análisis. La sensibilidad de los acelerómetros fue de 10mV/g.

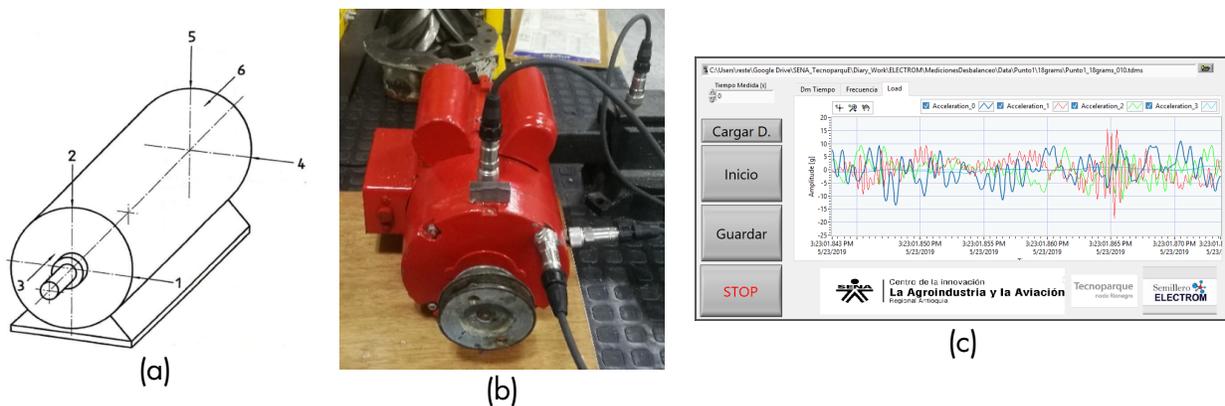


Fig. 2 Descripción del montaje sobre la máquina bajo análisis. (a) Puntos de medición estáticos según ISO10186-1:1995. (b) Montaje experimental. (c) Interfaz de adquisición de datos desarrollada

La máquina bajo observación fue modificada con un sistema de pesos que permitía controlar los gramos de desbalance sobre el eje y medir los efectos sobre los puntos de medida, los cuales fueron realizados sobre la carcasa del motor. Se ejecutaron variaciones del nivel de desbalance a partir de la inserción de masas de 8g, 18g, 25g, 38g y 50g. Las mediciones se realizaron en los tres ejes principales X, Y, Z y un acelerómetro fue puesto como referencia en el fundamento mecánico de la instalación. Dos puntos fueron analizados dentro de la máquina: un punto ubicado en la salida del eje de transmisión de fuerza (punto 1) y otro punto cercano al ventilador del motor (punto 2). Los puntos de medición se realizaron siguiendo los estándares presentados

en la ISO10186-1:1995. El motor bajo análisis consistió en un motor de inducción jaula de ardilla con velocidad sincrónica  $N_0 = 1800$  [r.p.m.], lo que representa una frecuencia fundamental alrededor de  $f_0 = 30$  [Hz]. La Fig. 1 presenta la descripción del montaje de los puntos de medición y la implementación experimental de los mismos. La Fig. 3 presenta el espectro de velocidad de los tres ejes bajo análisis. Los valores presentados en las figuras fueron calculados como niveles de velocidad  $L_V = 20 \log_{10}(V/V_0)$ , con nivel de velocidad de referencia de  $V_0 = 1 \text{ mm/s}$ . Cabe anotar que la condición inicial de la máquina corresponde ya a una situación de desbalanceo considerable y la existencia de armónicos asociados representa la existencia de múltiples problemas mecánicos. Para el caso en particular la existencia de múltiples armónicos permite inferir una situación de falla pre-existente por efectos de acoples o fundamentos mecánicos sueltos, la presencia del segundo armónico indica también la existencia de desbalances de la unidad bajo estudio.

Dado que el análisis de las componentes armónicas permite inferir ciertas propiedades de la condición de severidad de la máquina, estas componentes son utilizadas para la simplificación de los análisis.

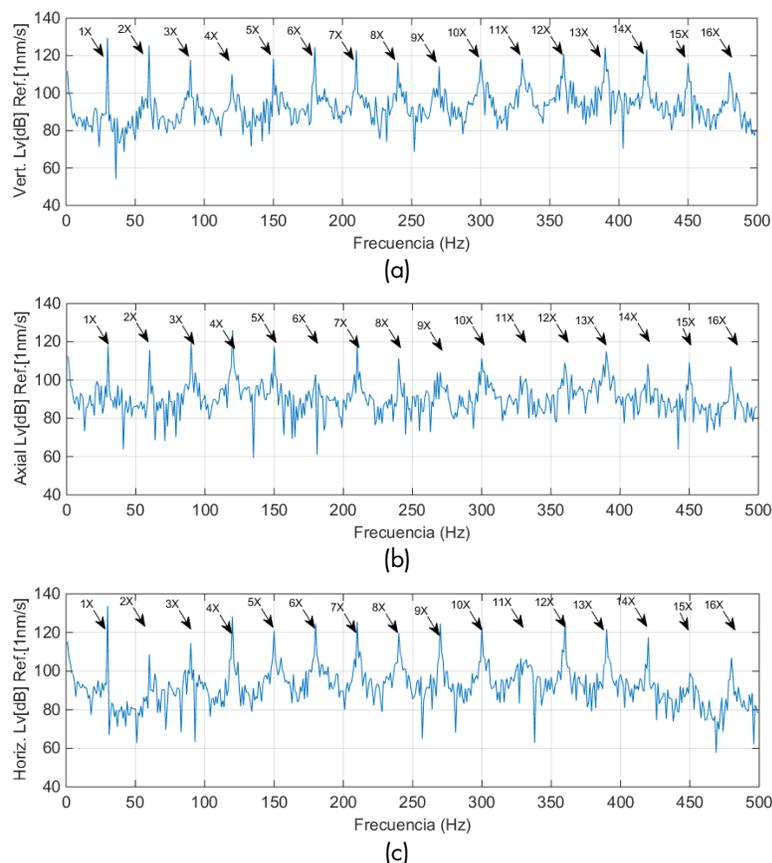


Fig. 3 Espectro normalizado en niveles de vibración de velocidad Lv. dB Ref. 1 mm/s. (a) Componente Vertical. (b) Componente Axial. (c) Componente Horizontal.

La Fig. 4 presenta los niveles de vibración en velocidad para los diferentes desbalances inducidos al eje de la máquina bajo estudio. Para este caso han sido seleccionados los primeros 5

armónicos de la señal de aceleración con el objetivo de validar el comportamiento de los niveles de vibración en función de dicho desbalance para cada uno de los armónicos. Tal como se puede observar de los datos obtenidos, los niveles de vibración aumentan claramente para las frecuencias normalizadas 1X para las componentes axiales y verticales.

### a. Entrenamiento del clasificador estadístico

Esta subsección presenta el proceso de entrenamiento del clasificador estadístico, para este caso se utilizó la herramienta libre WEKA (Frank Eibe, Hall Mark A., 2016), para la determinación de clases y asociación de las observaciones. Inicialmente se deben definir la cantidad de atributos que harán parte del clasificador. Para este caso tendremos 6 tipos de clases nominales asociadas a cada uno de los desbalances que quieren ser determinados por el clasificador. Para cada una de las instancias de datos se seleccionaron 17 atributos por clase, donde se definen las primeras 5 frecuencias normalizadas para cada uno de los ejes analizados. Se realizó una clasificación utilizando inicialmente el algoritmo de árbol de decisión J48 considerando todo el conjunto de datos.

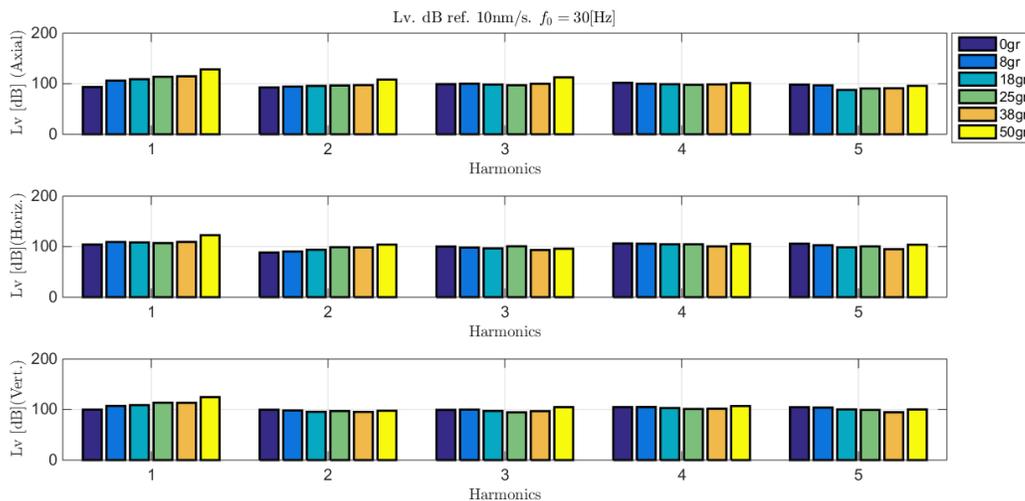


Fig. 4 Niveles de vibración (velocidad dB referencia 10nm/s) en las frecuencias normalizadas 1X, 2X, 3X, 4X y 5X, para diferentes niveles de desbalanceo 0gr, 8gr, 18gr, 25gr, 38gr y 50gr.

La Fig. 5(a) presenta la correlación de datos del primer armónico en para los ejes horizontal y vertical. Esta correlación es esperada debida a que el tipo falla inducida tiene afecciones en plano del desbalance. Por otro lado, un resultado importante dentro del desarrollo experimental fue la correlación encontrada entre las mediciones en el eje axial y el eje vertical para la misma componente fundamental en diferentes condiciones de falla. Para este caso, los resultados se asocian a un fenómeno de transferencia de energía vibratoria propio de la condición de falla inducida y la condición existente de los fundamentos mecánicos de la instalación, lo que resulta en un aumento de las vibraciones en el eje axial a medida que se incrementa la severidad de la falla. La Fig. 5(b) presenta el comportamiento de linealidad observado entre ambas variables analizadas.

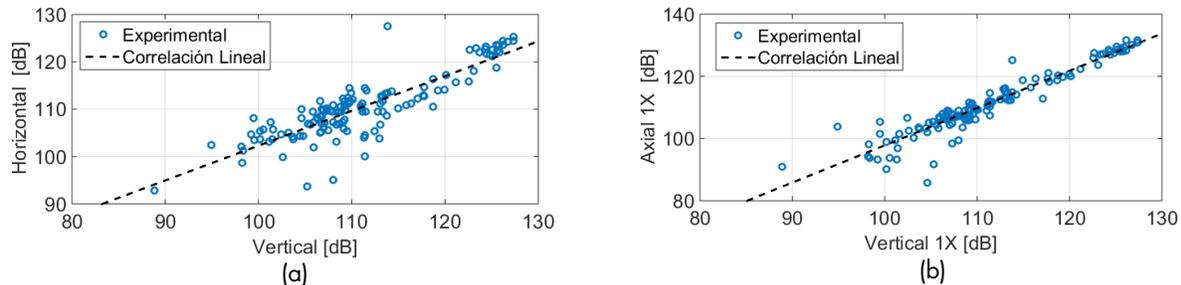


Fig. 5 Correlación lineal encontrada entre las mediciones de los niveles de velocidad para la componente fundamental en los ejes. (a) Ejes horizontal y vertical (factor de proporcionalidad  $k=0.73$ ). (b) Ejes axiales y verticales (factor de proporcionalidad  $k=1.2$ ).

Para la implementación de los clasificadores estadísticos y los algoritmos de inteligencia artificial correspondientes, se planteó una reducción progresiva de elementos para simplificar el modelo, de manera que se ignoraron los atributos asociados a frecuencias superiores y se implementó una clusterización de datos basado en distancia euclidiana (Lloyd, 1982) para las tres componentes de interés ubicándolas en los ejes X,Y,Z de un sistema coordenado de referencia. La Fig. 6 (a) presenta una representación tridimensional de los niveles de velocidad medidos para las tres componentes bajo análisis. Los centroides identificados representan los niveles de severidad asociados a las diferentes condiciones de falla. Dado que la clasificación se realiza en función de la distancia euclidiana a alguno de estos centroides, se ha incluido una esfera de cercanía al centroide para indicar la pertenencia al clúster de cada uno de los datos. Tal como se puede inferir de la Fig. 6 (a), la intersección de estos espacios de clasificación define las zonas de transición de los niveles de severidad y se permite además observar la trayectoria de evolución de la falla en función de los niveles de velocidad medidos en cada uno de los ejes. Es importante resaltar las agrupaciones encontradas dentro de la región de situación inicial y situación crítica para los diferentes niveles de falla, definen las regiones geométricas de un tipo de falla en particular (para el caso de estudio el desbalanceo inducido). Otro tipo de regiones del espacio pueden ser pobladas con datos asociados a otro tipo de fallas y pueden ser utilizados para la identificación de nuevos modos de falla que no están incluidos en este caso.

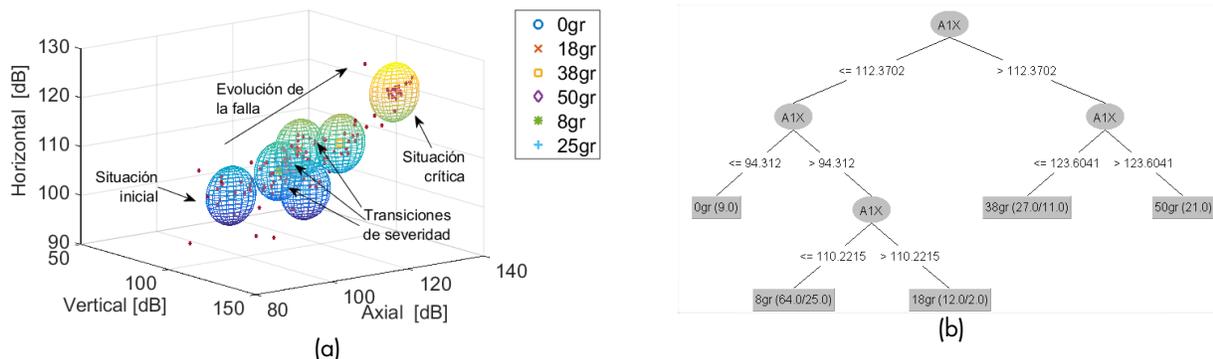


Fig. 6 Resultados de clasificación estadística. (a) Visualización de la clusterización en frecuencia normalizada 1X para la componente Vertical, Axial y Horizontal. (b) Árbol simplificado de clasificación basado en la componente axial a la frecuencia normalizada 1X.

Finalmente, el desempeño de cada uno de los modelos fue analizado y fue siendo simplificado en función de los porcentajes de predicción. Los mejores modelos de predicción del nivel de desbalance fueron seleccionados en función de su simplicidad, obteniendo finalmente un modelo de un solo atributo considerando la primera frecuencia normalizada de un acelerómetro vigilando la componente axial. La Fig. 6 (b) presenta el árbol de decisión obtenido para un solo acelerómetro.

#### **4. Conclusiones**

El presente trabajo presenta los resultados experimentales del análisis de condición de máquinas rotativas, mediante la conciliación de fundamentos teóricos, el comportamiento esperado en niveles de vibración y el desempeño de clasificadores estadísticos de inteligencia artificial, con el fin de simplificar modelos de predicción que dan soporte al proceso de definición del estado de severidad de los análisis de mantenimiento basado en la condición. La metodología implementada concluye sobre la simplificación del análisis a partir de un único acelerómetro en la posición axial lado eje y en el análisis del primer armónico y presenta los procesos de clusterización como metodología adecuada para la identificación de zonas de transición de severidad y evolución de falla.

#### **5. Referencias**

##### **Artículos de revistas**

- Candanedo, I. S., González, S. R., & Muñoz, L. (2018). Diseño de un Modelo Predictivo en el Contexto Industria 4.0. *KnE Engineering*, 3(1), 543.
- Finley William R., Hodowanec Mark M., (2000). An Analytical Approach to Solving Motor Vibration Problems. *IEEE Transactions on Industry Applications*, 36(5), 2000.
- Frank Eibe, Hall Mark A., and W. I. H. (2016). *The WEKA Workbench. Online Appendix for "Data Mining: Practical Machine Learning Tools and Techniques."* Morgan Kaufmann.
- Lloyd, S. (1982). Least squares quantization in PCM. *IEEE Transactions on Information Theory*, 28(2), 129–136.
- Lozano, G. (2007). *Análisis De Vibraciones En Elementos Rotacionales Con Variación De Temperatura, Para La Determinación De La Desviación De La Vida Útil.* (6), Avances Investigación en Ingeniería, pp 90–94. \
- Sepúlveda, M. (2017). Las Competencias Transversales, base del Aprendizaje para Toda la Vida. *Virtual Educa*, 1–19.
- Widodo, A., & Yang, B. S. (2007). Support vector machine in machine condition monitoring and fault diagnosis. *Mechanical Systems and Signal Processing*, 21(6), 2560–2574

##### **Libros**

- Quinlan, R. (2004). *Programs for Machine Learning.* Morgan Kaufmann Publishers, Inc.,

- 1993.
- White, P. G. (2010). *Introducción al Análisis de Vibraciones*, Azima DLI.

### Fuentes electrónicas

- Laverde, H. A. (2016). *El mantenimiento para la era de la industria 4.0, Cero Averías*.
- Mais, J. (2002) *Spectrum Analysis: The key features of analyzing spectra.*, 1 SKF, Inc. 32.
- Quintanar, T. L. (2007). *Generalidades de los Sistemas Expertos*, Tesis, Universidad Autónoma del Estado de Hidalgo, México.

### Sobre los Autores

- **Héctor Freddy Cardona**, Ingeniero Mecánico, Especialista en Mantenimiento. Desde el año 2014, se desempeña como Instructor SENA en programas de mantenimiento en el Centro de la Innovación, la Agroindustria y la Aviación (CIAA). hfcardona11@misena.edu.co
- **Yonny Valencia**, Aprendiz SENA, estudiante de Tecnología en Mantenimiento Electromecánico Industrial en el Centro de la Innovación, la Agroindustria y la Aviación (CIAA). Actualmente hace parte del Semillero de Mantenimiento Electromecánico-ELECTROM del área industria del CIAA.
- **Esteban Jiménez**, Ingeniero Electricista, Magíster en Ingeniería Eléctrica. Actualmente se desempeña como Gestor Tecnológico Línea de Electrónica y Telecomunicaciones, Tecnoparque Nodo Rionegro, del SENA (CIAA). rejimene@unal.edu.co

---

Los puntos de vista expresados en este artículo no reflejan necesariamente la opinión de la Asociación Colombiana de Facultades de Ingeniería.

Copyright © 2019 Asociación Colombiana de Facultades de Ingeniería (ACOFI)