

Mantenimiento predictivo de motores de corriente directa empleando redes neuronales artificiales

Jonathan Villanueva Tavira, Juan González Serna,
Andrés Blanco Ortega, Héctor Buenabad Arias,
Edgardo de Jesús Carrera Avendaño

Tecnológico Nacional de México,
Centro Nacional de Investigación y Desarrollo Tecnológico
México

`andres.bo@cenidet.tecnm.mx`

Resumen. El Mantenimiento Predictivo es la técnica que utiliza la Inteligencia Artificial con la finalidad de predecir fallas. La principal contribución de este trabajo es la metodología para procesar y utilizar los datos obtenidos a partir de las vibraciones de los motores de corriente directa, ya que son elementos muy empleados en proyectos de robótica móvil. Posteriormente, con los datos almacenados tanto de motores de corriente directa en buen y mal estado, se construye una red neuronal artificial entrenada con un algoritmo de aprendizaje no supervisado, con la finalidad de hacer grupos con los datos recabados de los motores de corriente directa. Para concluir la etapa de experimentación se realizaron experimentos con otros métodos de aprendizaje automático como: árboles de decisión, máquinas de soporte vectorial y k vecinos más cercanos.

Palabras clave: Redes neuronales artificiales, inteligencia artificial, mantenimiento predictivo.

Predictive Maintenance of Direct Current Motors Using Artificial Neural Networks

Abstract. Predictive Maintenance is the technique that utilizes Artificial Intelligence to predict failures. The main contribution of this work is the methodology for processing and using the data obtained from the vibrations of direct current motors, as they are widely used in mobile robotics projects. Subsequently, with the stored data from both good and faulty direct current motors, an artificial neural network is built and trained with an unsupervised learning algorithm to cluster the collected data from the direct current motors. To conclude the experimentation phase, experiments were conducted with other machine learning methods such as decision trees, support vector machines, and k-nearest neighbors.

Keywords: Artificial neural networks, artificial intelligence, predictive maintenance.

1. Introducción

Los ingenieros en la industria constantemente buscan maneras de evitar el mantenimiento correctivo con la finalidad de reducir los costos que implica. El control, seguimiento y mantenimiento de los equipos que se encuentran en una línea de producción son actividades fundamentales para la calidad y desempeño de los procesos productivos [1, 2, 3, 4, 5]. Los sensores y principalmente los motores juegan un papel importante para máquinas como: bandas transportadoras, generadores, mezcladoras, compresores, hornos, soldadoras, entre otras. Para garantizar su óptimo funcionamiento estas deben de estar constantemente monitoreadas y realizar su respectivo mantenimiento [5].

El Mantenimiento Predictivo es la técnica que utiliza la Inteligencia Artificial con la finalidad de predecir fallas. Este enfoque permite a los ingenieros o técnicos encargados del mantenimiento realizar la corrección de los equipos antes de que se averíen, lo que hace que el tiempo de vida útil de los equipos se prolongue.

Este tipo de mantenimiento presenta varias ventajas como: reducción del tiempo de inactividad no planificada, ayuda a la identificación de fallas del equipo mediante el monitoreo, y finalmente, disminuye el tiempo de inactividad al reducir el tiempo para inspeccionar y realizar reparaciones. Sin embargo, la desventaja que presenta este enfoque, es la necesidad de contar con sistemas basados en Internet de las Cosas, por lo que implantarlo en un inicio podría representar un costo alto. Este tipo de mantenimiento no solo permite predecir alguna falla, si no también identificar las partes que pueden estar fallando en sus equipos estimando el tiempo de la falla en la maquinaria (Ver Figura 1) [6].

Los costos que conlleva el mantenimiento en una empresa o industria pueden representar desde el 15% al 60% total del costo del producto fabricado. Por ejemplo, en la industria de los alimentos el costo promedio del mantenimiento asciende al 15% del total del bien producido; en contraste con las industrias del ramo metalmeccánica que utilizan en sus productos materiales como: hierro, acero y papel representa un costo del 60% del total de producto fabricado.

La industria estadounidense cada año gasta más de 200 mil millones de dólares en mantenimiento de equipos e instalaciones en las plantas de producción. El resultado de una mala administración al ejecutar un plan de mantenimiento representa una pérdida de más de 60 mil millones de dólares cada año y tiene un impacto directamente sobre el tiempo de producción y la calidad del producto [6].

Se entiende por mantenimiento a un conjunto de acciones o técnicas que permiten prolongar el tiempo de vida útil de un equipo, asegurando el costo mínimo y garantizando la seguridad para el usuario [6].

La importancia de mantenimiento industrial radica en que en la Industria Mexicana es necesario mantener el equipo y la maquinaria funcionando de forma continua y eficientemente. El mantenimiento se puede clasificar de en tres tipos: preventivo, correctivo y predictivo (ver Figura 1).

El pronosticar el tiempo de la falla en una línea de producción o en un equipo puede ayudar a programar de una forma más eficiente el mantenimiento del mismo [7] (ver Figura 2).



Fig. 1. Clasificación de los tipos de Mantenimiento Industrial [7].




Fig. 2. Descripción gráfica del Mantenimiento Predictivo [7].




Fig. 3. Diagrama a bloques de los tipos de aprendizaje [8].

2. Red neuronal artificial de Kohonen

Esta arquitectura de Red Neuronal Artificial (RNA) tiene una característica muy particular a diferencia de las demás Redes Neuronales Artificiales. Se trata de una RNA de aprendizaje no supervisado, que son aquellas que no requieren un supervisor externo para realizar su aprendizaje. Esto consiste en que la red descubra por sí sola características o categorías con los datos de entrada y se obtengan de forma codificada a la salida [8] (Ver Figura 3).

El objetivo de esta RNA es categorizar los datos de entrada. Se trata de que los datos que son muy parecidos sean clasificados como pertenecientes a la misma categoría. En estos modelos suele existir una capa de clasificación compuesta por tantas neuronas como categorías puedan existir en los datos. Cada categoría está representada por un




Fig. 4. Arquitectura del aprendizaje competitivo [8].

prototipo cuyas características son una especie perteneciente a un grupo con características similares. En la capa de clasificación, cada neurona corresponde a un prototipo. La arquitectura de una red neuronal artificial con aprendizaje competitivo consiste en dos capas denominadas F1 y F2, donde F1 es la capa de entrada y recibe las señales del entorno. La capa F2 es la que se encarga de producir la salida [8] (Ver Figura 4).

El científico finlandés, Teuvo Kohonen, diseñó un modelo adaptable a las características de los sistemas neuronales, consiste en una red neuronal de dos capas, una primera capa de entrada y una segunda de competencia. La capa de entrada recibe la señal de entrada, su dimensión depende de los atributos de entrada. Cada neurona de entrada está conectada a todas las células de la capa de competición. Este algoritmo no concluye después de presentarle una vez todos los patrones de entrada, ya que este proceso debe de repetirse varias veces para conseguir que la red neuronal pueda realizar una clasificación más exacta. [9, 10]. A continuación, se describe el algoritmo de la red neuronal de Kohonen:

- a) En primer lugar, se inicializan los pesos w_{ij} con valores aleatorios menores a uno y se fija la zona inicial de la vecindad entre las neuronas de salida (Ver Figura 5).
- b) De tal forma que la matriz de pesos quedaría de la siguiente forma, con un radio $R=0$ y una tasa de aprendizaje del $\alpha = 0.6$.

$$\begin{bmatrix} 0.2 & 0.6 & 0.4 & 0.4 & 0.2 \\ 0.3 & 0.5 & 0.7 & 0.6 & 0.8 \end{bmatrix}.$$

- c) Se debe de calcular la distancia euclídea para saber cuál neurona se parece más a los datos de entrada. Para este paso se realiza mediante la siguiente expresión:

$$D(j) = \sum (w_{ij} - x_i)^2. \quad (1)$$

- d) Posteriormente, se presenta a la red la información de entrada (los patrones a reconocer) en forma de vector (0.3,0.4). Y se calcula la distancia euclídea para ver cuál de las neuronas es más parecida a los datos de entrada.

$$D(1) = (0.2 - 0.3)^2 + (0.3 - 0.4)^2 = 0.02 ,$$

$$D(2) = (0.6 - 0.3)^2 + (0.5 - 0.4)^2 = 0.10 ,$$

$$D(3) = (0.4 - 0.3)^2 + (0.7 - 0.4)^2 = 0.10 ,$$

$$D(4) = (0.4 - 0.3)^2 + (0.6 - 0.4)^2 = 0.50 ,$$

$$D(5) = (0.4 - 0.3)^2 + (0.6 - 0.4)^2 = 0.17 .$$




Fig. 5. Topología de la Red Neuronal Artificial de Kohonen [9].

- e) Como se observa la primera neurona en este caso, es la que más se parece a los datos de entrada, por lo que se deben de actualizar los pesos de ella y de sus vecinas. Para la actualización de pesos se realiza a partir de la siguiente expresión:

$$w_{ij(new)} = w_{ij(old)} + \alpha (x - w_{ij(old)}), \quad (1)$$

$$\begin{aligned} w_{11(new)} &= w_{11(old)} + 0.3(0.3 - 0.2), \\ w_{11(new)} &= 0.2 + 0.3(0.3 - 0.2), \\ w_{11(new)} &= 0.23, \end{aligned} \quad (2)$$

$$\begin{aligned} w_{21(new)} &= w_{21(old)} + \alpha (x - w_{21(old)}), \\ w_{21(new)} &= 0.3 + 0.3(0.4 - 0.3), \\ w_{21(new)} &= 0.33. \end{aligned} \quad (3)$$

- f) Una vez que se actualizaron los pesos, se deberán de sustituir esos pesos en la matriz de pesos de la red antes de la actualización de las vecinas:

$$\begin{bmatrix} 0.2 & 0.6 & 0.4 & 0.4 & 0.2 \\ 0.3 & 0.5 & 0.7 & 0.6 & 0.8 \end{bmatrix}, \quad \begin{bmatrix} 0.23 & 0.6 & 0.4 & 0.4 & 0.2 \\ 0.33 & 0.5 & 0.7 & 0.6 & 0.8 \end{bmatrix}.$$

Debido a la actualización de los pesos, se deben de actualizar también las neuronas vecinas a la neurona ganadora. Para ello, también aplicamos la actualización de los pesos a la neurona dos:

$$\begin{aligned} w_{12(new)} &= w_{12(old)} + \alpha (x - w_{12(old)}), \\ w_{12(new)} &= 0.6 + 0.3(0.3 - 0.6), \\ w_{12(new)} &= 0.51, \end{aligned} \quad (4)$$

$$\begin{aligned} w_{22(new)} &= w_{22(old)} + \alpha (x - w_{22(old)}), \\ w_{22(new)} &= 0.5 + 0.3(0.4 - 0.5), \\ w_{22(new)} &= 0.47. \end{aligned} \quad (5)$$

Una vez que se actualizaron los pesos, se deberán de sustituir esos pesos en la matriz de pesos de la red. Este proceso deberá de repetirse hasta que los pesos se estabilicen, algunos autores proponen que el entrenamiento debe de realizarse en 300 épocas para lograr unos pesos estables [9, 10]:




Fig. 6. Red Neuronal Artificial de Kohonen con sus pesos [10].




Fig. 7. Descripción gráfica de la metodología de solución [6].

$$\begin{bmatrix} 0.23 & 0.6 & 0.4 & 0.4 & 0.2 \\ 0.33 & 0.5 & 0.7 & 0.6 & 0.8 \end{bmatrix}, \quad \begin{bmatrix} 0.23 & 0.51 & 0.4 & 0.4 & 0.2 \\ 0.33 & 0.47 & 0.7 & 0.6 & 0.8 \end{bmatrix}.$$

En la figura 6 se observa la topología de la red neuronal artificial con sus pesos al finalizar la primera parte del entrenamiento [10].

3. Metodología de solución

La Inteligencia artificial en conjunto con el Internet de las Cosas (IoT) han permitido potencializar este último tipo de mantenimiento en la industria. En la actualidad es más sencillo obtener los datos de los equipos industriales mediante las herramientas del IoT. Estos datos, combinados con técnicas de Inteligencia Artificial como lo son las Redes Neuronales Artificiales se emplean para construir los modelos de predicción de fallas [11]. A continuación, se detallan los pasos empleados en esta metodología de solución (ver Figura 7).

- a) **Identificación de las Condiciones.** Para realizar los experimentos se toman como parámetros las vibraciones de los motores de corriente directa. Las vibraciones mecánicas están relacionadas con el mantenimiento predictivo, ya que proporcionan indicadores de fallos presentes o posibles a mediano plazo. Las vibraciones pueden causar aumento de esfuerzos y tensiones, deformaciones superiores al margen elástico, fatiga en los materiales, desgaste y pérdida de energía y mayor consumo energético. La razón por la que se eligió la variable vibración es porque el estudio de las mismas permite detectar un estado general del

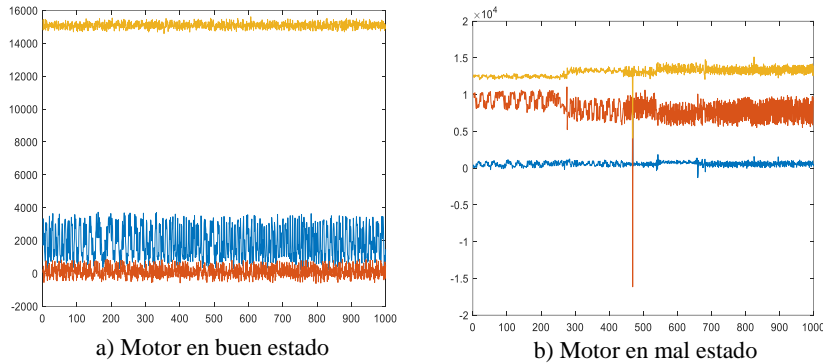


Fig. 8. Datos generados por el motor de corriente directa en buen y mal estado obtenidos por el giroscopio.




Fig. 9. Datos generados por el motor en mal estado obtenidos por el giroscopio vistos en 3D.

funcionamiento de las máquinas, así como el desequilibrio, desalineamientos, defectos en rodamientos y cojinetes, fallos de lubricación, entre otros [6].

- b) Recolección de los datos.** En lo que concierne a esta segunda etapa, mediante una rutina de adquisición de datos provenientes de un giroscopio y un acelerómetro, estos se colocaron directamente en los motores con la finalidad de poder recolectar la información correspondiente para cada motor. En este caso, se emplearon dos motores de corriente directa de las mismas características, uno en buen estado y uno desgastado con la finalidad de contrastar las lecturas provenientes de los sensores. Esta información recopilada, conforma el Dataset para experimentar con los datos obtenidos por los sensores. En la figura 8 se muestran los 2000 datos tomados en un periodo de 1 segundo cada uno de los motores. Las gráficas resultantes muestran una variación de las medidas proporcionadas por el sensor de acuerdo al estado del motor.

Adicionalmente, en la figura 9 se muestran estos mismos datos graficados en tres dimensiones con la finalidad de tener otra perspectiva de los datos generados por los sensores de las vibraciones de los motores de corriente directa.




Fig. 10. a) Plano de Conjuntos, b) Plano de Pesos de la Red Neuronal Artificial.




Fig. 11. Diagrama a bloques de la metodología de la solución.

- c) **Entrenamiento del Modelo.** En esta etapa, se realiza el entrenamiento de la red neuronal a partir de los datos con la finalidad de agrupar en distintos clusters las lecturas provenientes de los sensores tanto del motor en buen estado, como en mal estado. En la figura 10 se observa las ubicaciones de las neuronas en la topología de la red neuronal artificial e indica la cantidad de observaciones que están asociadas para cada una de las neuronas. La topología seleccionada es de 2x2, por lo que existen 4 neuronas en total en la red.
- d) **Validación del Modelo.** Para esta etapa, con la finalidad de comprobar el funcionamiento de la red neuronal artificial, se realiza la exportación de la misma a una función de tipo MATLAB para poder emplearla en una interfaz. La finalidad de esta etapa consiste en monitorear el estado del motor con los sensores que nos emiten las vibraciones y estas mismas sirven como entrada a la Red Neuronal Artificial desplegando el resultado de la red en una interfaz gráfica (Ver Figura 11).

4. Comparación con otra técnica de Red Neuronal Artificial

En esta sección se presentan las pruebas realizadas, así como los resultados obtenidos después de aplicar el algoritmo de entrenamiento para cada uno de los conjuntos de datos. Adicionalmente, se realiza la comparación empleando una red neuronal artificial de aprendizaje supervisado con el algoritmo de retropropagación con la finalidad de contar con dos algoritmos de apoyo para predecir alguna posible




Fig.12. Gráfica del error de la red neuronal artificial.

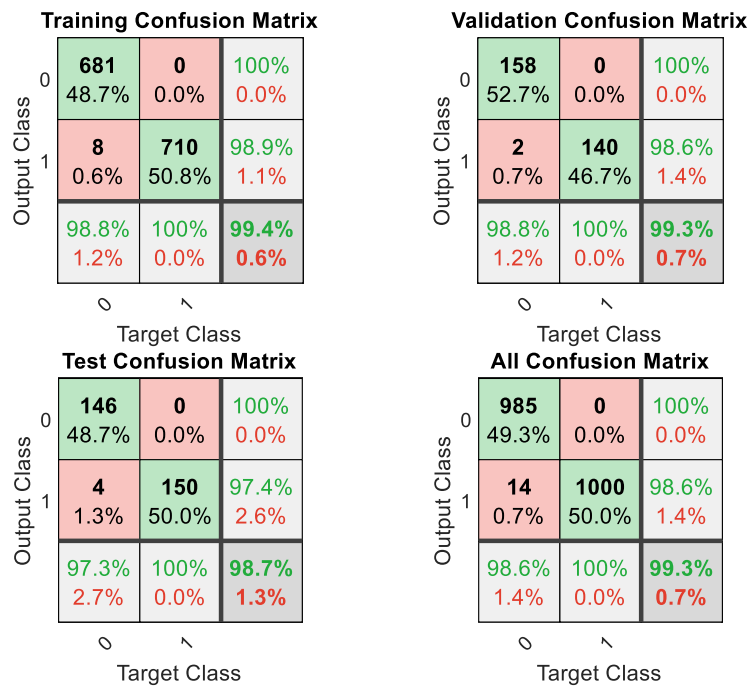


Fig. 13. Matriz de Confusión de la Red Neuronal Artificial.

descompostura de los motores, detectando en tiempo y forma vibraciones anormales en los parámetros de su funcionamiento. Para ello se emplea una red neuronal multicapa entrenada con el algoritmo backpropagation. (Ver Figura 12)

En la figura 13 se muestra la Matriz de Confusión que despliega los datos de la red neuronal al artificial con el porcentaje de clasificación correcta y errónea. En lo que

Tabla 1. Comparación con otros métodos de clasificación.

Algoritmo	Precisión
Árbol de Decisión	99.8 %
Máquina de Soporte Vectorial	96.5 %
KNN	99.9 %
Máquina de Soporte Vectorial Cúbica	99.4 %

respecta a esta técnica empleada para realizar la clasificación de las vibraciones de motores de corriente directa en bueno y mal estado. Esto permite hacer nuestro sistema más robusto, ya que las dos técnicas se aplicarán en paralelo con la finalidad de detectar las vibraciones anormales en el funcionamiento de un motor en buen estado.

Los resultados obtenidos en el entrenamiento de la red neuronal artificial muestran que estos modelos logran el objetivo, ya que se implementaron en un sistema en tiempo real para realizar el monitoreo de los motores de corriente directa y detectar alguna falla asociada a la vibración de los motores. Es importante mencionar, que las redes neuronales artificiales presentan la desventaja que son vistas como cajas negras y no pueden explicar la forma en que llegaron a un resultado. Por lo anteriormente, esbozado se realiza la comparación con otras técnicas de clasificación como árboles de decisión y máquinas de soporte vectorial, obteniendo los siguientes resultados (Ver Tabla 1).

5. Conclusiones

Cada día más las empresas buscan formas más eficientes de aplicar técnicas que apoyen en la toma de decisiones en la línea de producción prediciendo cuándo puede presentarse alguna falla en algún equipo o proceso reduciendo el costo y la carga de trabajo. Los objetivos de este trabajo y sus principales contribuciones son proponer una metodología para utilizar los datos de las vibraciones de los motores de corriente directa y con ellos, construir y entrenar dos modelos de redes neuronales artificiales capaces de predecir cuándo puede ocurrir una falla. En primera instancia se implementa una red neuronal artificial de aprendizaje no supervisado y en segunda se emplea un modelo de aprendizaje supervisado. Finalmente, el segundo modelo se compara con otras técnicas de clasificación obteniendo un nivel alto de precisión.

Referencias

1. Patan, K., Korbicz, J., Głowacki, G.: DC Motor Fault Diagnosis by Means of Artificial Neural Networks. In: Proceedings of the Fourth International Conference on Informatics in Control, Automation and Robotics, Angers, France, pp. 11–18 (2007). DOI: 10.5220/0001625400110018.
2. Gongora, W.S., Silva, H.V.D., Goedel, A., Godoy, W.F., da Silva, S.A.O.: Neural Approach for Bearing Fault Detection in Three Phase Induction Motors. In: Proceedings of the 2013 9th IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives (SDEMPED), Valencia, Spain, 27–30, pp. 566–572 (2013). DOI: 10.1109/DEMPED.2013.6645771.

3. Kouki, M., Dellagi, S., Achour, Z., Erray, W.: Optimal Integrated Maintenance Policy based on Quality Deterioration. In: Proceedings of the 2014 IEEE International Conference on Industrial Engineering and Engineering Management, Malaysia, pp. 9–12, pp. 838–842 (2014). DOI: 10.1109/IEEM.2014.7058756.
4. Amihai, I., Gitzel, R., Kotriwala, A.M., Pareschi, D., Subbiah, S., Sosale, G.: An Industrial Case Study Using Vibration Data and Machine Learning to Predict Asset Health. In: Proceedings of the 2018 IEEE 20th Conference on Business Informatics (CBI), pp. 11–14, pp. 178–185 (2018). DOI: 10.1109/CBI.2018.00028.
5. Scalabrini-Sampaio, G., Vallim-Filho, A.R.A., Santos da Silva, L., Augusto da Silva, L.: Prediction of Motor Failure Time Using an Artificial Neural Network. *Sensors*, vol. 19, no. 19, pp. 4342 (2019). DOI: 10.3390/s19194342.
6. Mobley, R.K.: *An Introduction to Predictive Maintenance*, Elsevier Science (2002)
7. *Introduction to Maintenance with MATLAB*.
8. Isasi Viñuela, P., Gaván Leon, I.M.: *Redes de Neuronas Artificiales: Un enfoque práctico*. Pearson Prentice Hall (2004)
9. Hernando, J.R.: *Redes Neuronales Artificiales: Fundamentos, Modelos y Aplicaciones*. Ra-Ma (1994)
10. Sivanandam, S.N.: *Introduction to Neural Networks using MATLAB 6.0*. Mc Graw Hill Education (2006)
11. Abbasi, J.A.: *Predictive Maintenance in Industrial Machinery using Machine Learning*. Lulea University of Technology Department of Computer Science, Electrical and Space Engineering (2021)