

Sistema de clasificación de severidad de desalineación motor-eje mediante redes neuronales convolucionales

Motor-axis misalignment severity classification system using convolutional neural networks

José Pablo Pérez Calderón*, Benjamín Arroyo Ramírez, Horacio Orozco Mendoza
Facultad Tecnológica Nacional de México en Celaya, Antonio García Cubas Pte #600 esq. Av. Tecnológico, Celaya, C.P. 38010, México
*perezcapablo@gmail.com

Resumen

En maquinaria rotativa, la desalineación es una de las principales causas de vibración y puede verse afectada por diversos factores. En los últimos años, se han empleado métodos de aprendizaje automático para la detección de fallas en maquinaria rotativa. Por lo tanto, en este trabajo se expone una metodología para la clasificación de la severidad de desalineación angular y paralela, mediante el entrenamiento de un modelo de red neuronal convolucional con los espectros de frecuencia, obtenidos de los soportes de los rodamientos del eje para cada condición operativa. El conjunto de datos para el entrenamiento se generó de forma experimental en un banco de pruebas diseñado y fabricado con este fin, variando la magnitud de la desalineación del sistema. Los resultados de los modelos entrenados mostraron 100% de precisión en la clasificación con datos de validación para la desalineación angular y de 90% para el caso de la desalineación paralela.

Abstract

In rotating machinery, misalignment is one of the main causes of vibration and can be affected by various factors. In recent years, machine learning methods have been employed for the detection of faults in rotating machinery. Therefore, in this paper, a methodology for the classification of angular and parallel misalignment severity by training a convolutional neural network model with the frequency spectra, obtained from shaft bearing supports for each operating condition is presented. The training data set was generated experimentally on a test rig designed and fabricated for this purpose by varying the misalignment magnitude of the system. The results of the trained models showed 100% classification accuracy with validation data for angular misalignment and 90% for parallel misalignment.

Palabras clave:

Desalineación, vibraciones, RNC

Keywords:

Vibration, misalignment, CNN

Introducción

El análisis de vibraciones es considerado como la mejor alternativa para la evaluación del estado mecánico de maquinaria [1]. Requiere una captura correcta de la señal de vibración y la aplicación de técnicas de análisis, como el análisis espectral, para la detección e identificación de sus causas.

Cerca del 90% de los problemas de vibración en maquinaria rotativa se encuentran en tres condiciones: desalineación, desbalanceo y resonancia con porcentajes de 30%, 40% y 20% respectivamente [2].

Además, la desalineación es la segunda causa más común de vibración en maquinaria rotativa [2-4], y se considera la causante de cerca del 70% de sus problemas mecánicos [5]. Esta puede ser el resultado de factores como el ensamblado de la máquina, deformación debido a variaciones de temperatura, asimetría en la carga aplicada, entre otras [3].

Debido a la gran cantidad de maquinaria que presenta desalineación y los altos porcentajes de vibración asociados con

ella, se ha definido como objeto de estudio en esta investigación.

El análisis de vibraciones, realizado tradicionalmente por expertos en cada problema particular, hoy en día es una herramienta de alto valor diagnóstico, ampliamente estudiado y aplicado. Sin embargo, diversos investigadores lo han complementado con técnicas de aprendizaje automático para la detección y la clasificación de fallas en maquinaria rotativa.

Problemas como la desalineación, el desbalanceo, daños en los rodamientos pueden ser identificados mediante algoritmos de aprendizaje automático, mostrando ser una herramienta de utilidad para la mejora de las técnicas de mantenimiento basado en la condición.

Desde los años 70's, la desalineación ha sido estudiada mediante técnicas de inteligencia artificial. En [6] se estudió la desalineación entre un motor y un dinamómetro, dieron

un procesamiento a las señales para obtener su densidad espectral de potencia (PSD), a la cual realizaron un análisis de componentes principales para emplearlos en el entrenamiento de una red neuronal.

Actualmente, la desalineación angular y paralela continúan siendo un tema de estudio con técnicas de inteligencia artificial. En [5] estudiaron estas condiciones ante distintas velocidades de operación. Emplearon las señales de vibración y la corriente del motor para el diagnóstico de fallas, a través de una técnica de entropía multiescala en combinación con una red neuronal de propagación hacia atrás. Reportan una correcta identificación de distintos tipos de desalineación. Por su parte, en [7] emplearon una extracción de características multiaxiales y máquinas de soporte vectorial para la clasificación de condiciones de desalineación y desbalanceo, reportando un 100% de precisión.

Una de las técnicas empleadas para el aprendizaje profundo (deep learning), son las redes neuronales convolucionales (CNN), las cuales han mostrado ser una herramienta de gran utilidad para la clasificación y la detección de defectos en imágenes [8]. Además, presentan la capacidad de extraer automáticamente características de las imágenes, sin la necesidad de conocimiento especializado para el preprocesamiento de los datos [8,9].

Dicho lo anterior, en el trabajo presentado en [10] emplean la transformada de tiempo corto de Fourier (STFT) para pasar las señales de vibración de una dimensión a una matriz de dos dimensiones (imágenes). Estas imágenes se utilizan para el entrenamiento de una CNN para la clasificación de severidades de desbalanceo, detección de desgaste en los rodamientos y de desgaste en chavetas. En su investigación se obtuvieron resultados de clasificación correcta del 100 % ante datos de prueba.

Del mismo modo, en [11] emplean los espectrogramas de la señal de vibración como imágenes de entrada para el entrenamiento de un modelo de CNN, con un enfoque en la clasificación de cuatro severidades de desbalanceo en las aspas de un aerogenerador bajo dos velocidades de operación. Además, se emplea la técnica para la clasificación entre rodamientos sanos y con daño. El autor reporta una precisión en la clasificación del 100%.

Por su parte, en [9] emplean una metodología basada en un espectro multivariable y CNN para la detección de desbalanceo en turbinas de viento. Obtuvieron que su método es capaz de detectar desbalance aerodinámico y desbalance de masa con muy buenos resultados.

Por otro lado, en [12] presentan una metodología para la predicción de fallos con un enfoque en turbocompresores. Emplean la metodología CRISP-DM con técnicas de redes neuronales y lógica difusa para la predicción y toma de decisiones de mantenimiento. Reportan resultados de precisión en la clasificación del 99.9%.

Finalmente, en [13] muestran una recopilación de trabajos recientes de ML enfocado al mantenimiento predictivo para maquinaria rotativa, turbocompresores, bombas industriales, etc. Encontraron que los algoritmos más utilizados para la predicción corresponden a; máquinas de soporte vectorial (SVM), bosque aleatorio (RF) y redes neuronales artificiales (ANN). Siendo el algoritmo RF es el más utilizado para técnicas de mantenimiento predictivo.

Este trabajo tiene como objetivo realizar la clasificación del nivel de severidad de desalineación de un banco de pruebas de vibraciones, mediante sus espectros de frecuencia. Por tal razón, al tratarse de una tarea de clasificación de imágenes, se propone una metodología que utiliza redes neuronales convolucionales, debido a su capacidad de aprender automáticamente las características de los datos.

En la segunda sección del documento se detalla la metodología empleada para la generación de las condiciones experimentales, el procesamiento de las señales y la generación del conjunto de imágenes para el entrenamiento de los modelos CNN.

Para el desarrollo experimental, se emplea un banco de pruebas conformado por un servomotor Baldor BSM90C3150-AF con un acoplamiento flexible a un eje que tiene montados un par de volantes para generar desbalanceo dinámico. La velocidad del sistema es regulada mediante un controlador FDH2A07-EN20.

Las señales de vibración son adquiridas mediante acelerómetros uniaxiales tipo ICP, montados en la dirección axial de los soportes de los rodamientos a una velocidad constante de 1000 rpm y con un tiempo de adquisición de datos de un minuto por prueba.

Posteriormente, en la sección tres se presentan los resultados de la clasificación de los diferentes niveles de desalineación angular y paralela. Finalmente, en la sección cuatro se exponen las conclusiones de la investigación.

Instrumentación y metodología

Instrumentación

Para el desarrollo de este proyecto se empleó un banco de pruebas diseñado y fabricado con la finalidad de estudiar las señales de vibración resultantes de una condición operativa con presencia de desalineación entre ejes y desbalanceo en rotores, ver la Fig. 1. El banco permite la generación de desalineación angular y paralela entre el eje del servomotor y el eje acoplado, con un rango limitado a 1.5 mm para cada uno de los soportes.

Como sistema motriz se utilizó un servomotor Baldor modelo BSM90C3150-AF y un controlador FlexDrive^{II} FDH2A07-EN20. A través de estos, se opera el sistema en el rango de 0-1200 rpm. Las características técnicas se presentan en la Tabla 1.

Tabla 1- Características técnicas servomotor - controlador.

Instrumento	Características
	Torque: 7.2 Nm
Servomotor	Corriente pico: 15.4 A
BSM90C3150-AF	Potencia: 1.66 KW
	Velocidad máxima: 7000 rpm
	Alimentación: 220 V CA
Controlador - servo	24 V CD
	Velocidad máxima: 2000 rpm

La configuración experimental se muestra en la Fig. 1. En la Tabla 2 se presenta una breve descripción de los instrumentos empleados y sus características.

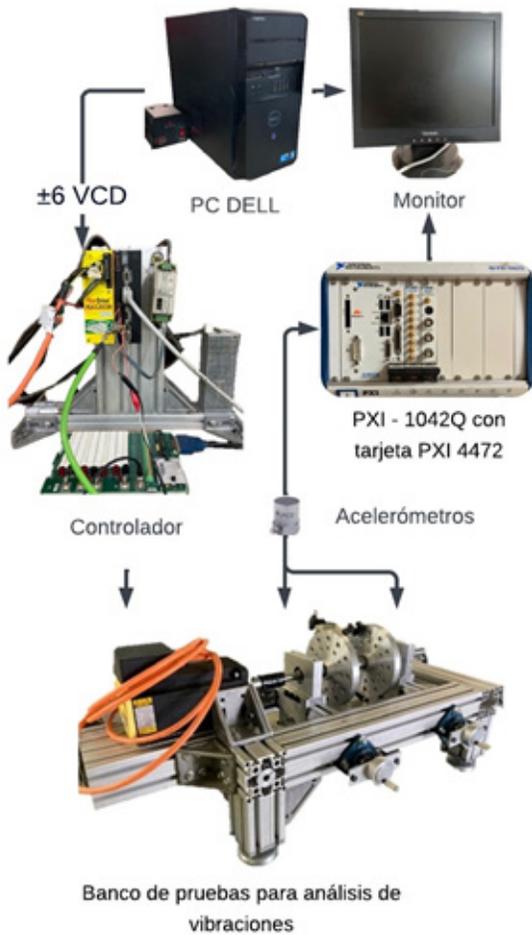


Figura 1. Configuración experimental.

Parámetros de adquisición

La adquisición de datos se realizó con una frecuencia de muestreo de 1.024kS/s y un tiempo de adquisición de 10s por captura. Cada espectro de vibración corresponde al promedio de seis capturas, lo que representa un tiempo de adquisición de datos de un minuto por prueba.

Para generar los espectros de vibración se utilizó un programa creado en LabVIEW, véase la Fig. 2. Mediante este, se obtuvo el espectro de magnitud pico para la aceleración y la velocidad en cada soporte.

Tabla 2- Instrumentos empleados para DAQ.

Instrumento	Función / Características
NI PXI 1042Q con tarjeta	Adquisición y procesamiento de señales de vibración para obtención de los espectros
NI 4472	8 canales de entrada analógicos con tasa de muestreo de 102.4KS/s
Dell Vostro 430.	Habilitar y deshabilitar el servomotor, control de velocidad del sistema. Procesador Intel® Core™ i7
Acelerómetro PCB 352C33	Obtención de señales de vibración del soporte 1 Rangos: ± 490 m/s ² . pk, 0.5-10000 Hz
Acelerómetro PCB 353B33	Obtención de señales de vibración del soporte 2 Rangos: ± 490 m/s ² . pk, 1-4000 Hz
Banco de pruebas	Operar ante distintas severidades de desalineación angular y paralela.

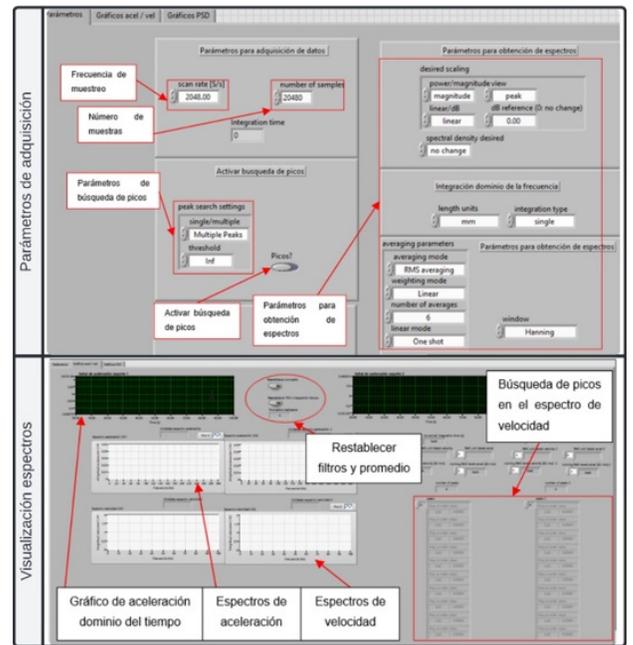


Figura 2. Programa para visualización de espectros de vibración.

Los detalles de los parámetros empleados para el procesamiento de las señales para la obtención de los espectros de velocidad se presentan en la Tabla 3.

Generación de las condiciones de interés

El sistema empleado brinda la posibilidad de generar una desalineación entre el eje motriz y el conducido mediante la rotación de un par de perillas ubicadas en los laterales del banco. Véase las Figs. 3 (a)-(b).

Tabla 3 – Parámetros para obtención de espectros.

Parámetro	Valor empleado
Filtro pasa bandas	10 – 150 Hz
Power Spectrum	
Ventana	Hanning
Promedio	RMS averaging
Weighting mode	Exponential
Número de promedios	6
Conversión de unidades de espectro	
Escalamiento aplicado	Magnitud
Linear / dB	linear
Vista	Peak
Densidad espectral deseada	Spectrum
Parámetros de integración	
Tipo de integración	Sencilla
Unidades	mm

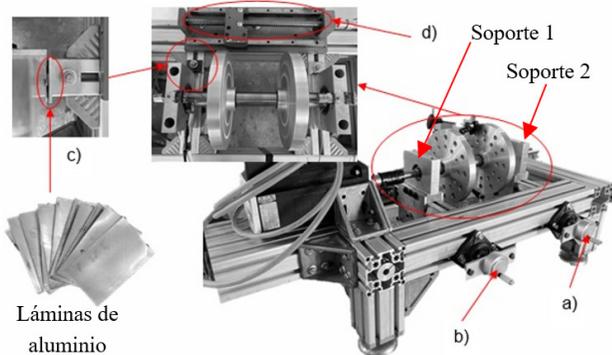


Figura 3. Generación de condiciones de desalineación. a) perilla de desalineación soporte 2, b) perilla de desalineación soporte 1, c) zona de colocación de láminas para desalineación y d) plataforma de montaje de comparador de pestaña.

El mecanismo de desalineación del sistema es simple, basta con girar las perillas mostradas en las Figs. 3(a)-(b) para desplazar los soportes uno y dos respectivamente. Sin embargo, con la finalidad de generar un nivel de desalineación lo más uniforme posible a lo largo de las pruebas, se colocaron pequeñas láminas de aluminio en la zona expuesta en la Fig. 3 (c).

La desalineación angular “DA”, fue generada mediante el desplazamiento del soporte del rodamiento dos. Por su parte, la desalineación paralela “DP”, se generó mediante el desplazamiento en la misma dirección e igual magnitud de ambos soportes.

Se estudiaron cuatro niveles de severidad para DA, los cuales corresponden a la colocación de 0, 4, 8 y 12 láminas de aluminio, es decir, desplazamientos de 0, 0.43, 0.86 y 1.26mm respectivamente. Estas cantidades representan geoméricamente desviaciones angulares en el eje de 0° , 0.08° , 0.16° y 0.23° respectivamente, y por tanto serán etiquetados de esta forma.

En cuanto a la DP, se estudiaron tres niveles de severidad

correspondientes al uso de 0, 4 y 8 láminas, lo que implica desplazamientos en el eje de 0, 0.43 y 0.86 mm respectivamente.

Conjunto de datos

Se realizó un total de 30 mediciones por condición de prueba. Esto con base a lo observado del desempeño del modelo entrenado en [14].

El modelo de CNN fue entrenado a través de las imágenes de los espectros de velocidad de vibración. Su empleo es recomendado cuando se tiene una máquina operando en el rango de 600 – 60000 rpm [15].

Investigadores y especialistas del área coinciden en la dirección axial como la indicada para la búsqueda de armónicos de la frecuencia de operación para la detección de la desalineación [2,15]. En la Fig. 4(a)-(c) se muestran los espectros obtenidos en cada dirección.

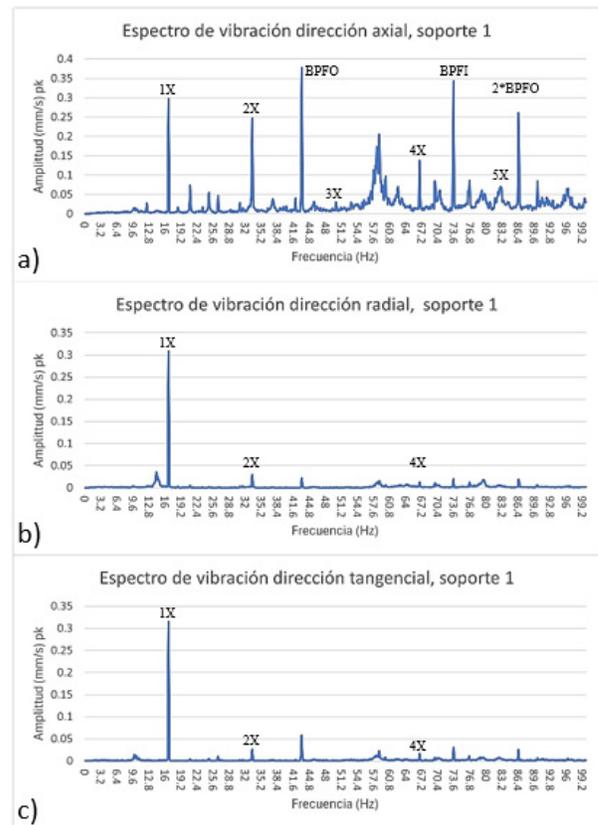


Figura 4. Comparativa de espectros en dirección a) axial, b) radial y c) tangencial.

De la Fig. 4 resulta evidente el incremento en la amplitud de los armónicos de la frecuencia fundamental con una medición en la dirección axial. A su vez, en la Fig. 4 a) se observa un pico a 43 Hz, denotado por BPFO y un armónico para la frecuencia de 86 Hz. Estas frecuencias corresponden al paso de las bolas por un defecto en el anillo exterior. Por su parte, la frecuencia denotada por BPF1 representa el paso de las bolas por un defecto en el anillo interior.

Con base en lo observado de los espectros de la Fig. 4, se decidió realizar la captura de los espectros de vibración en dirección axial para la generación del banco de imágenes.

El conjunto de imágenes se generó mediante la captura de pantalla del panel frontal del instrumento virtual (vi) desarrollado en LabVIEW, este contiene el promedio de seis espectros consecutivos, que dan un total de un minuto de adquisición de datos.

Las imágenes capturadas son de 1024 x 768 pixeles, en formato de color de 32 bits, ver la Fig. 5. Cada imagen contiene cuatro gráficas, correspondientes a los espectros de velocidad y a los espectros de aceleración.

Cabe señalar que se realizaron pruebas para determinar la mayor amplitud al variar los niveles de desalineación, resultando un valor pico de 0.5 mm/s. Este se definió como parámetro para escalar el eje de la amplitud. En la Fig. 5 se muestran los espectros resultantes de una desalineación angular de 0.23° para ambos soportes en el rango de 0-100Hz, bajo una velocidad de operación de 1000 rpm.

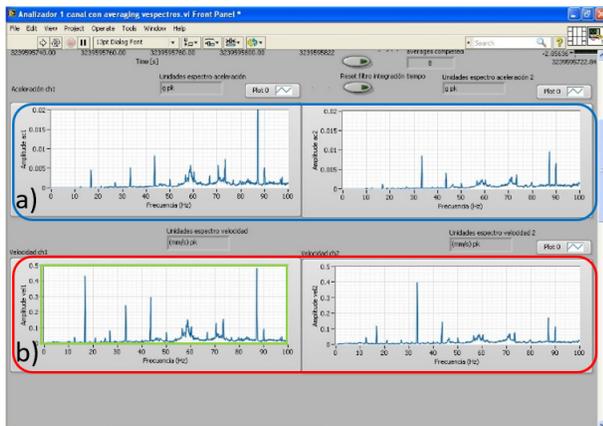


Figura 5. Imágenes empleadas para la generación de la base de datos de condiciones de desalineación. a) espectros de aceleración, b) espectros de velocidad.

La separación de los espectros para la creación de la base de datos para cada soporte fue realizada mediante un programa desarrollado en Python. Este código recorta cada una de las imágenes en la región cuadrículada del espectro. Dicha área se ejemplifica mediante el recuadro color verde en la Fig. 5 (b). La imagen resultante presenta un tamaño de 414 x 132 pixeles.

A continuación, en la Fig. 6 se expone la comparativa entre los espectros resultantes de las condiciones de severidad estudiadas para la DA.

Cabe señalar que el nivel de desalineación angular denotado como 0° en la Fig. 6 corresponde a la condición inicial de desalineación, tomada como punto base para el desarrollo de las pruebas. Del mismo modo, se puede observar la pre-

sencia de armónicos de la frecuencia de operación para la condición 0° , esto representa la presencia de cierto grado de desalineación residual. A pesar de esto, en los espectros de la Fig. 6 resulta evidente la variación de la amplitud de la frecuencia de operación y sus armónicos. Para la visualización de estas variaciones, ver la Fig. 7.

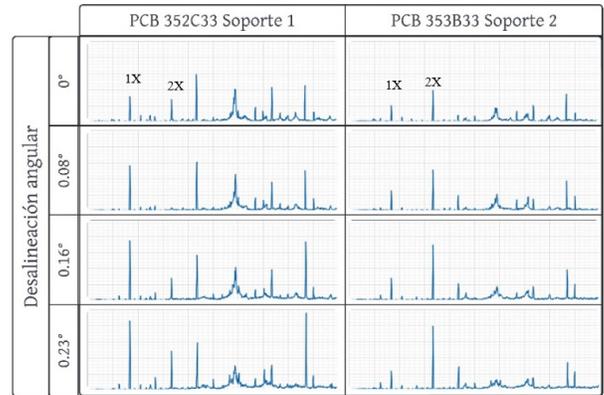


Figura 6. Espectros resultantes de diferentes condiciones de desalineación angular.

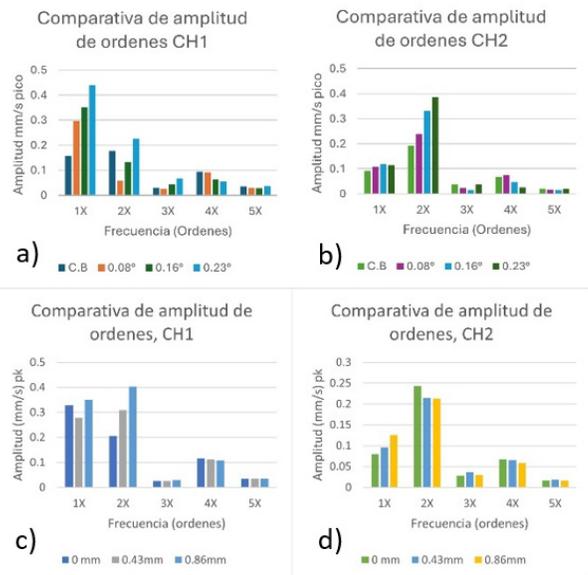


Figura 7. Comparativa del promedio de amplitud de órdenes, registrada ante distintos niveles de desalineación: a) angular, soporte 1, b) angular, soporte 2, c) paralela, soporte 1, d) paralela, soporte 2.

En la Fig. 7 se muestran los valores de la amplitud de órdenes promedio de las pruebas realizadas para el caso de la desalineación angular y paralela. Se denota como órdenes a los múltiplos enteros de la frecuencia de operación. A partir de la figura anterior, se muestra que una variación en el nivel de desalineación del sistema tiene como resultado una variación de amplitud en la frecuencia correspondiente a la velocidad angular del sistema y sus armónicos. Nótese que, a partir de la desalineación generada al sistema, los principales cambios en amplitud corresponden a 1X y 2X.

Integración del banco de imágenes

Uno de los requisitos para el entrenamiento de un modelo de red neuronal convolucional es contar con una base de datos formada por imágenes previamente etiquetadas. Se obtuvo una base de datos con un total de 210 imágenes para el entrenamiento y validación del modelo CNN para cada soporte de los rodamientos.

Estas imágenes fueron separadas en tres carpetas correspondientes a datos de entrenamiento, validación y prueba. Los datos fueron divididos de acuerdo con lo expuesto en la Tabla 4. Se denotará la condición base para las pruebas como “CB”.

Tabla 4 – Etiquetas para clasificación de fallas.

Condición	Etiqueta	En.	Val.	Pr.
DA CB	0°	20	6	4
DA 0.08°	0.08°	20	6	4
DA 0.16°	0.16°	20	6	4
DA 0.23°	0.23°	20	6	4
DP CB	0 mm	20	5	5
DP 0.43 mm	0.43 mm	20	5	4
DP 0.86 mm	0.86 mm	20	5	5

Estas carpetas fueron cargadas en *Google Drive* para desarrollar la programación y entrenamiento del modelo mediante la plataforma de *Google Colaboratory*.

Colab es un servicio gratuito alojado en Jupyter Notebook que proporciona acceso a recursos informáticos. Resulta especialmente adecuado para el aprendizaje automático, ciencia de datos y educación. [16].

Programación y entrenamiento del modelo

Para el desarrollo de este trabajo se optó por emplear Python como lenguaje de programación al poderse trabajar con software libre y debido al gran soporte y librerías enfocadas al aprendizaje automático con las que cuenta. Para la programación del modelo se usó la biblioteca Keras, diseñada para ser modular, rápida y fácil de usar, es de código abierto y se ejecuta sobre frameworks como Theano y TensorFlow [17].

La arquitectura de red neuronal convolucional que mostró mejores resultados se muestra en la Fig. 8. Está conformada por un par de capas de convolución seguidas del proceso de discretización Max pooling para la reducción de la dimensionalidad de los mapas de características. Este proceso se repite dos veces más, incrementando el número de filtros en las capas de convolución de 8 a 16 y 32. Se aplica una capa de aplanamiento para convertir los mapas de características en un vector unidimensional que será la capa de entrada a un clasificador tradicional. Para el caso de la DP, el modelo dio mejores resultados omitiendo la capa completamente conectada de 16 neuronas.

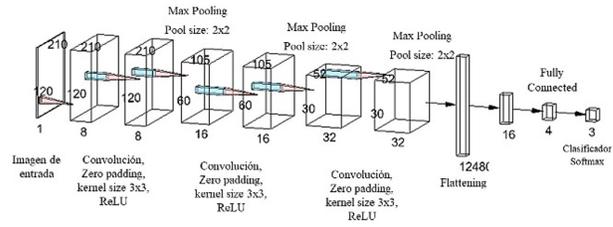


Figura 8. Modelo CNN empleado.

Para la programación del modelo fue necesario definir una serie de parámetros e hiperparámetros, los valores empleados para el entrenamiento del modelo CNN se muestran en la Tabla. 5.

Tabla 5 – Parámetros empleados para el entrenamiento de los modelos CNN.

Parámetro	Valor empleado
Tasa de aprendizaje	0.001
Optimizador	Adam
Loss	categorical_crossentropy
Desalineación angular	
Imagen de entrada	60 x 210 pixeles
Canales	3
Tamaño del lote	5
Dropout	0.5 en capa de 16 neuronas
Desalineación paralela	
Imagen de entrada	120 x 210 pixeles
Canales	3
Tamaño del lote	5
Dropout	0.5 en capa de 4 neuronas
Early Stopping	
Épocas máximas	100
Métrica	val_loss
Paciencia	3

En una CNN, las capas convolucionales tienen la función de extraer características de la imagen de entrada. Por su parte, las capas completamente conectadas son esencialmente un perceptrón multicapa, el cual contiene una capa de entrada, capas ocultas y la capa de salida que representa el clasificador mediante una función de activación tipo Softmax.

Las imágenes fueron cargadas al modelo mediante la función ImageDataGenerator de Keras, mediante la cual, se aplicó únicamente un ajuste de escala a estas.

Posteriormente, el desempeño del modelo se evaluó mediante matrices de confusión ver la Fig. 10, curvas de precisión Fig. 9 (a) y pérdida Fig. 9 (b).

Resultados y discusión

A partir de las pruebas realizadas, se obtuvo un excelente desempeño de clasificación para los modelos de desalineación angular. Sin embargo, para el caso de la desalineación

paralela, se obtuvo un porcentaje del 93 % de precisión ante datos de validación para ambos soportes y del 78% y 64% ante datos de prueba para el soporte uno y dos respectivamente. La explicación de los resultados se expone a continuación.

Desalineación angular

El modelo expuesto en la Fig. 8 presentó excelentes resultados de clasificación de los cuatro niveles de severidad, a pesar del reducido número de muestras generadas para su entrenamiento.

El desempeño del modelo se evaluó observando los parámetros de precisión y pérdida reportados por el programa al final de cada época de entrenamiento.

La precisión indica la relación entre las predicciones verdaderas correctas y el número total de predicciones [8]. Por su parte, la pérdida es usada para medir que tan bien una red neuronal se desempeña [18]. Por tal razón, resultó importante monitorear ambos valores durante el entrenamiento del modelo.

Los gráficos de precisión y pérdida resultantes del entrenamiento de los modelos del soporte uno y dos se muestran en la Fig. 9.

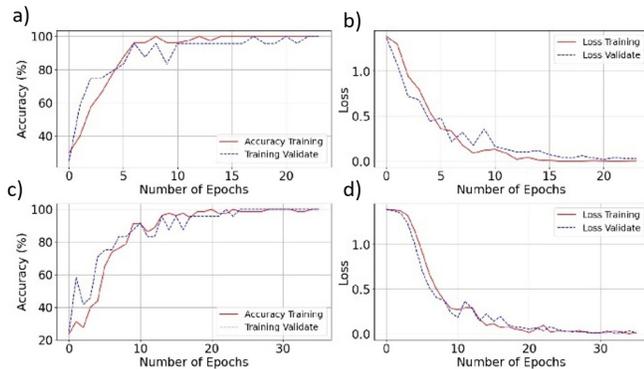


Figura 9. Gráficos para evaluación del desempeño del modelo con datos de soporte uno: a) precisión, b) pérdida. Con datos del soporte dos: c) precisión, d) pérdida.

De los gráficos mostrados en la Fig. 9 se observa una tendencia creciente en la precisión, así como una tendencia decreciente del valor de la pérdida de los datos de validación. Esto es un buen indicativo acerca del entrenamiento del modelo.

En las Figs. 10 (a)-(b) se muestran las matrices de confusión resultantes de la evaluación del modelo con datos de validación y con datos adicionales que fueron empleados como prueba.

Cabe destacar que los modelos del soporte uno y dos presentaron 100% de precisión en la clasificación. Por tal razón, las matrices mostradas en la Fig. 10 representan a ambos modelos.

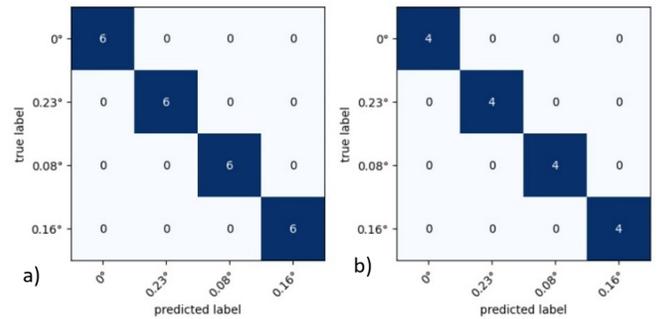


Figura 10. Matrices de confusión de los modelos entrenados con datos del soporte uno y dos para desalineación angular; a) validación, b) prueba.

En la Fig. 10 se muestran matrices que contienen en el eje horizontal las clases predichas por el modelo y en el eje vertical las clases verdaderas. Una clasificación con una precisión del 100% se muestra con todos los números dentro de la diagonal, tal como es el caso de esta figura.

Desalineación paralela

La desalineación paralela presentó una mayor complejidad en la configuración experimental. La necesidad de desplazar ambos soportes influyó en la uniformidad de los datos resultantes de las mediciones, ya que pequeñas diferencias de desplazamiento o ajuste en cualquiera de los soportes influyen en variaciones en los niveles de amplitud en los espectros. Vea la Fig. 11.

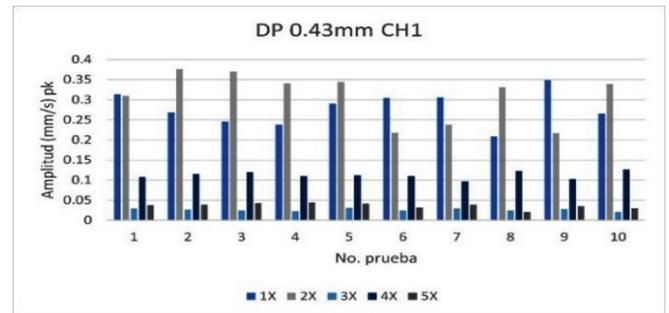


Figura 11. Variación de la amplitud de órdenes en soporte uno ante distintos niveles de desalineación paralela.

Se expone la imagen anterior puesto que permite la visualización de las variaciones en las amplitudes de la frecuencia fundamental y sus armónicos.

De la evaluación de los modelos se obtuvieron porcentajes de precisión ante datos de validación del 93% para ambos soportes. Sin embargo, al someterlos ante datos de prueba, se observó una disminución importante en el desempeño, resultando en porcentajes de clasificación correcta del 78% para el soporte uno y del 64% para el soporte dos.

En la Fig. 12 se muestran los gráficos de precisión y pérdida resultantes del entrenamiento de los modelos.

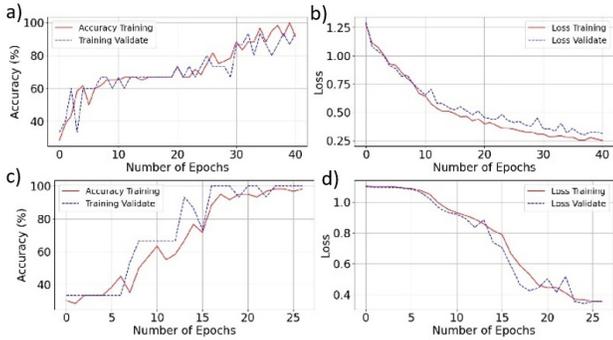


Figura 12. Gráficos para la evaluación del desempeño del modelo con datos del soporte uno: a) precisión, b) pérdida. Con datos del soporte dos: c) precisión, d) pérdida.

Al igual que para el caso de la desalineación angular, en la Fig. 12 se observa una tendencia creciente en la precisión y decreciente en los gráficos de pérdida. Se probaron los modelos ante datos de validación y de prueba, resultando en las matrices de confusión que se muestran en la Fig. 13.

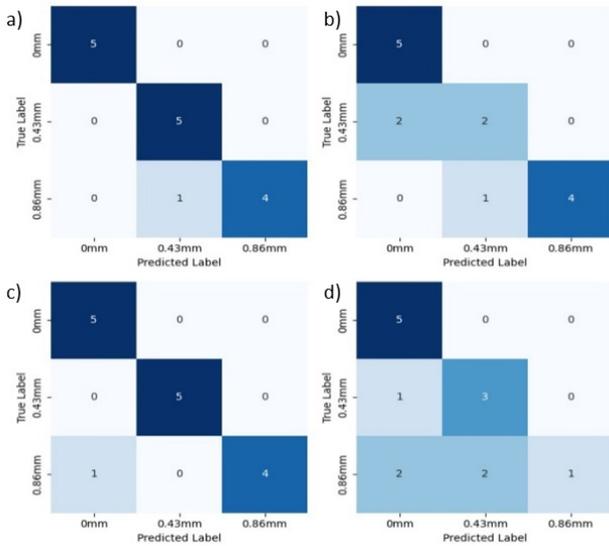


Figura 13. Matrices de confusión de los modelos entrenados con datos de desalineación paralela del soporte uno: a) validación, b) prueba. Y del soporte dos: c) validación, d) prueba.

De la Fig. 13 (b) y la Fig. 13(d) se observa que el modelo no presenta el mismo desempeño que con datos de validación. Indagando en los resultados de la clasificación, se revisaron los datos de prueba empleados para la evaluación del modelo. Se encontró que los datos de prueba para la condición 0.43 mm presentan un par de imágenes que concuerdan con su clasificación y otro par presentan un comportamiento que se asemeja al observado de los datos de entrenamiento para las etiquetas de 0mm. Véase la Fig. 14.

De la Fig. 14 se observa que el modelo identifica los cambios entre la magnitud de la frecuencia de operación y sus armónicos. Por lo cual, a pesar de obtener un bajo porcentaje de clasificación ante datos de prueba, se concluye que los problemas de clasificación no son por el modelo, sino por la calidad de los datos obtenidos para la desalineación paralela.

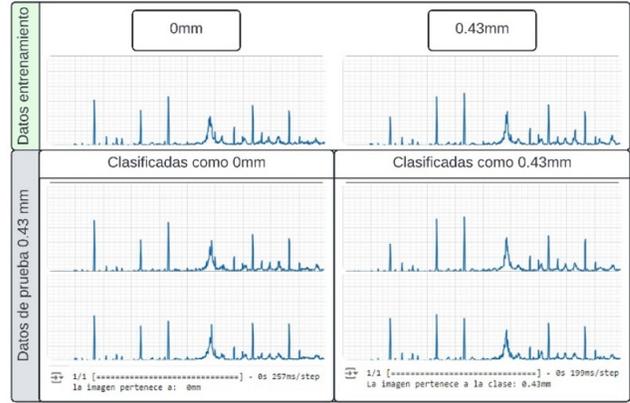


Figura 14. Análisis de los datos de prueba de la categoría 0.43 mm del soporte uno.

Conclusión

A lo largo de este trabajo se expuso una metodología en la cual se propone el empleo de una arquitectura de red neuronal convolucional para la clasificación de distintos niveles de severidad de desalineación angular y paralela en un sistema. El modelo propuesto mostró excelentes resultados para la clasificación de cuatro condiciones de desalineación angular, obteniendo un 100% de precisión en la clasificación ante datos de entrenamiento, validación y prueba. Lo cual es un indicativo de que la técnica empleada es viable como herramienta para el mantenimiento y el monitoreo de la condición de desalineación de este sistema.

Por su parte, la desalineación paralela, a pesar de obtener un porcentaje de precisión del 93% para ambos soportes ante datos de validación, los resultados ante datos de prueba mostraron que la metodología empleada para la generación de las condiciones requiere ajustes, es decir que cuando se mueva el sistema, la única variable afectada sea la desalineación paralela.

Agradecimientos

Al Consejo Nacional de Humanidades, Ciencias y Tecnologías (CONAHCYT) por la beca asignada para estudios de posgrado, mediante la cual fue posible desarrollar esta investigación y ser estudiante de tiempo completo.

REFERENCIAS

- [1] R. A. García-León, E. Flórez Solano y J. Pedroza, "Diseño de un banco de pruebas para el análisis de vibraciones mecánicas," *Revista Colombiana de Tecnologías de Avanzada*, vol. 1 no. 33, pp. 24-35, 2018.
- [2] V. Wowk. *Machinery Vibration Measurement and Analysis*, New York: McGraw-Hill, Inc. 1991.
- [3] T. H. Patel and A. K. Darpe, "Experimental investigations on vibration response of misaligned rotors," *Mech. Syst. Signal Process.*, vol. 23, n.º 7, pp. 2236–2252, October 2009. DOI: 10.1016/j.ymssp.2009.04.004

- [4] D. P. Hujare and M. G. Karnik, "Vibration responses of parallel misalignment in Al shaft rotor bearing system with rigid coupling," *Mater. Today: Proc.*, vol.5, n.º 11, Part 3, pp 23863-23871, 2018. DOI:10.1016/j.matpr.2018.10.178
- [5] A. K. Verma, S. Sarangi and M. Kolekar "Misalignment faults detection in an induction motor based on multi-scale entropy and artificial neural network," *Electric Power Components and Systems*, 44:8, pp 916-927, 2016, DOI:10.1080/15325008.2016.1139015.
- [6] J. J. Kuropatwinski, S. Jesse, J. W. Hines, A. Edmondson and J. Carley, "Prediction of motor misalignment using neural networks". February 1970, [Online]. Available: https://www.researchgate.net/publication/2717436_Prediction_Of_Motor_Misalignment_Using_Neural_Networks
- [7] M. M. Tahir, A. Hussain, S. Badshah, A. Q. Khan and N. Iqbal, "Classification of unbalance and misalignment faults in rotor using multi-axis time domain features," 2016 International Conference on Emerging Technologies (ICET), Islamabad, Pakistan, 2016, pp. 1-4, DOI: 10.1109/ICET.2016.7813273.
- [8] J.C. Muro-Villegas, S. Gómez-Jiménez, A. Robles-Guerrero, V. H. Baltazar- Hernández, E. A. López- Baltazar and T. Saucedo- Anaya. "Aplicación de redes neuronales convolucionales para clasificación del componente F-2304-201," *Memorias del XXIX Congreso Internacional Anual de la SOMIM, Ciudad Juárez, Chihuahua, México*, pp. MM12-MM21, septiembre 2023, DOI: 10.59920/JAAX4929.
- [9] Z. Cao, J. Xu, W. Xiao, Y. Gao and H. Wu, "A novel method for detection of wind turbine blade imbalance based on multi-variable spectrum imaging and convolutional neural network," 2019 Chinese Control Conference (CCC), Guangzhou, China, 2019, pp. 4925-4930, DOI: 10.23919/ChiCC.2019.8865600.
- [10] F. Ulloa Ríos y G. Barbieri "Detección de fallas en maquinaria rotativa: Implementación de una red neuronal convolucional," *Uniandes*, 2018. [En línea] Disponible en: <http://hdl.handle.net/1992/34072>
- [11] A. H. Rangel Rodríguez, "Análisis tiempo-frecuencia de vibraciones y redes neuronales convolucionales para detectar daño en aerogeneradores de baja potencia," *Tesis Maestría, Facultad de ingeniería, UAQ, San Juan del Río, Qro.* Mayo 2022.
- [12] L. Villegas y R. Pérez, "Inteligencia Artificial para Toma de Decisiones en el Mantenimiento Predictivo a equipos Turbocompresores en la Industria Petrolera", *Jornadas de Investigación de Postgrado*. [En línea]. Disponible: https://www.researchgate.net/profile/Leonardo-Villegas-Morphy/publication/371008558_Artificial_Intelligence_for_Decisions_Making_in_Predictive_Maintenance_to_Turbocompressors_Equipment_in_the_Oil_Industry/links/646ec6ca6a0082273fa89832/Artificial-Intelligence-for-Decisions-Making-in-Predictive-Maintenance-to-Turbocompressors-Equipment-in-the-Oil-Industry.pdf
- [13] Z. M. Çınar, A. Abdussalam Nuhu, Q. Zeeshan, O. Korhan, M. Asmael, B. Safaei, "Machine Learning in Predictive Maintenance towards Sustainable Smart Manufacturing in Industry 4.0," *Sustainability*, vol. 12, n.º 19, p.8211, October 2020. DOI:10.3390/su12198211
- [14] A. Luna Avilés y G. Bosques Brugada, "Análisis de vibraciones de un eje rotodinámico con redes neuronales artificiales y su aplicación al mantenimiento," *Memorias del XVIII Congreso Internacional Anual de la SOMIM, Salamanca, Gto., México*. pp. 1019-1025, septiembre 2012.
- [15] IRD Mechanalysis Inc, "IRD Mechanalysis Tecnología Vibración - I, Libro de texto", 1988
- [16] "colab.google". colab.google. Accedido el 5 de julio de 2024. [En línea]. Disponible: <https://colab.google/>
- [17] DataScientest (2024, enero 31). "Keras: todo sobre la API de Deep Learning". [En línea]. Disponible: <https://datascientest.com/es/keras-la-api-de-deep-learning>
- [18] A. Oppermann (2022, December 14) *How Loss Functions Work in Neural Networks and Deep Learning* [Online]. Available: <https://builtin.com/machine-learning/loss-functions>