

CLASIFICACIÓN DE CONDICIONES DE FUNCIONAMIENTO EN MÁQUINAS A PARTIR DE VIBRACIONES MECÁNICAS CON TÉCNICAS DE APRENDIZAJE AUTOMÁTICO

MACHINES OPERATING CONDITIONS CLASSIFICATION BASED ON MECHANICAL VIBRATIONS WITH MACHINE LEARNING TECHNIQUES

Emmanuel Beltramo^{a,b}, Martín E. Pérez Segura^{a,b}, Agostina C. Aichino^{a,b}, Santiago
Ribero^{a,b}, Bruno A. Rocca^c y Sergio Preidikman^{a,b}

^a*Instituto de Estudios Avanzados en Ingeniería y Tecnología (IDIT) - CONICET, Universidad Nacional de Córdoba, Av. Vélez Sarsfield 1611, 5000 Córdoba, Argentina. idit@fcefyn.edu.ar, <http://www.inv.idit.efn.uncor.edu/gmc>*

^b*Dpto. de Estructuras, Facultad de Ciencias Exactas, Físicas y Naturales, Universidad Nacional de Córdoba, Av. Vélez Sarsfield 1611, 5000 Córdoba, Argentina. depestructuras@fcefyn.unc.edu.ar, <http://www.efn.uncor.edu.ar/gia>*

^c*Bergen Offshore Wind Centre (BOW), Geophysical Institute, University of Bergen, Norway. PO Box 7800 5020 Bergen, Norway. post@uib.no. depestructuras@fcefyn.unc.edu.ar, <http://www.www.uib.no/gia>*

Palabras clave: Aprendizaje automático, clasificación de fallas, vibraciones mecánicas.

Resumen. La caracterización de la condición de funcionamiento de máquinas con técnicas de aprendizaje automático a partir de vibraciones mecánicas todavía se encuentra en una etapa exploratoria. En este trabajo, se propone un sistema inteligente basado en una red neuronal convolucional 1D. La red está diseñada para, luego del entrenamiento, ser capaz de caracterizar: i) la condición de funcionamiento normal (velocidad y nivel de carga); y ii) la condición de funcionamiento anormal, discerniendo entre cuatro posibles causas: desalineación, desbalance, falla en rodamientos y falta de lubricación. El set de datos utilizado incluye señales sintéticas y experimentales. Los resultados obtenidos son prometedores, mostrando un potencial por parte de la arquitectura para desempeñar con éxito su objetivo.

Keywords: Machine learning, faults classification, mechanical vibrations.

Abstract. The analysis machinery mechanical vibrations using machine learning techniques in order to characterize its operating condition is still in an exploratory stage. In this work, an intelligent classification system for the operating condition of machines based on a 1D convolutional neural network is proposed. After its training, the network is designed describe: i) the normal operating condition (speed and load level); and ii) the abnormal operating condition, discerning between four possible causes (misalignment, imbalance, bearing failure and lack of lubrication). The data set used includes synthetic and experimental signals. The results obtained are promising, showing a potential for the architecture to successfully fulfill its objective.

1. INTRODUCCIÓN

Las máquinas rotativas se han convertido en componentes esenciales de la industria moderna. Su confiabilidad es crucial para prevenir fallas prematuras, ya que éstas pueden comprometer la seguridad de los operadores y causar pérdidas económicas significativas (Alzghoul et al., 2021). En este contexto, un plan de monitoreo e identificación temprana de fallas es imprescindible para garantizar condiciones normales de funcionamiento. Las fallas más frecuentes que pueden experimentar este tipo de máquinas son desbalance, desalineación de ejes, falta de lubricación, holguras mecánicas, fisuras en los componentes de los rodamientos y en los engranajes de las cajas reductoras, entre otras (Muszynska, 2005).

El análisis de vibraciones se emplea desde hace mucho tiempo para monitorear el estado de condición de las máquinas (VCM, por sus siglas en inglés Vibration-based Condition Monitoring) con el propósito de identificar cualquier problema o anomalía (Sinha, 2020). Debido a que las vibraciones mecánicas son sensibles a cambios en los parámetros estructurales de una máquina, proporcionan información valiosa sobre su condición. En consecuencia, al analizar las características de las señales medidas a partir del espectro en frecuencia y/o forma de onda, es posible identificar diversas fallas debido a que cada una de ellas se manifiesta a través de patrones específicos. Sin embargo, para interpretar esta información e identificar anomalías y sus causas es imprescindible contar con personal idóneo que tenga amplia experiencia en el diagnóstico (Atmaja et al., 2024).

En la última década, los investigadores han comenzado a explorar la posibilidad de introducir técnicas de inteligencia artificial en la industria, y la monitorización del estado de las máquinas no ha sido la excepción. El empleo de esta tecnología no solo permite automatizar la identificación y clasificación de fallas, sino que también reduce la necesidad de intervención de personal especializado y contribuye a acortar los tiempos de diagnóstico e incrementar su eficiencia (Liu et al., 2018).

En general, los métodos inteligentes de diagnóstico se basan en modelos de machine learning tradicional o de deep learning. En cuanto a los primeros, los algoritmos más utilizados incluyen la máquina de soporte vectorial (SVM, por sus siglas en inglés Support Vector Machine), los K vecinos más cercanos (KNN, por sus siglas en inglés K -nearest Neighbors), y el clasificador de Naive Bayes. Con respecto a los segundos, las redes neuronales prealimentadas (FFNN, por sus siglas en inglés Feedforward Neural Networks) y las redes neuronales convolucionales (CNN, por sus siglas en inglés Convolutional Neural Networks), tanto en una dimensión (1D) como en dos dimensiones (2D), son los modelos de mayor difusión. Para una revisión exhaustiva de los trabajos más destacados en este campo, el lector puede consultar Zhao et al. (2019), Lei et al. (2020) y Zhu et al. (2023).

En el presente trabajo se propone un sistema inteligente basado en una red neuronal convolucional 1D para caracterizar la condición operativa de una máquina rotativa. La arquitectura de la red ha sido diseñada para identificar tanto el funcionamiento normal como cuatro tipos específicos de fallas: desbalanceo, desalineación, falta de lubricación y fallo de rodamiento. El modelo se entrena a partir de señales de aceleración en el dominio del tiempo, obtenidas de dos conjuntos de datos distintos: uno generado sintéticamente y otro derivado de mediciones experimentales. El objetivo de este trabajo es llevar a cabo una exploración inicial para entender cómo se comportan estos algoritmos en la clasificación de fallas. La organización del trabajo es la siguiente: en la sección 2 se describen los conjuntos de datos, en la sección 3 se detalla la arquitectura de la red. Por su parte, en la sección 4 se presentan y comentan los resultados obtenidos y, por último en la sección 5 se sintetizan las conclusiones más importantes.

2. CONJUNTOS DE DATOS

El conjunto de datos que se emplea en este trabajo se construye a partir de dos sets diferentes. El primero de ellos está compuesto por señales sintéticas diseñadas para simular las fallas más comunes en máquinas rotativas, mientras que el segundo proviene de mediciones experimentales realizadas sobre un dispositivo especialmente creado para reproducir fallas.

2.1. Señales generadas sintéticamente

Este set de datos consta de 1600 señales de aceleración en el dominio del tiempo. Cada una de ellas se generó con una frecuencia de muestreo (f_r) de 24 kHz y se compone de 4096 puntos muestrales. Del total, 800 señales corresponden a estados de funcionamiento normal, y las 800 restantes se distribuyen uniformemente entre cuatro tipos de fallas: desbalanceo, desalineación, falta de lubricación y falla de rodamiento. Todas las señales están asociadas a una velocidad de operación constante de 1500 rpm, excepto en el caso de las señales normales, de las cuales la mitad corresponden a una velocidad de 1800 rpm. En la Figura 1, se muestra una señal representativa para cada uno de los casos mencionados.

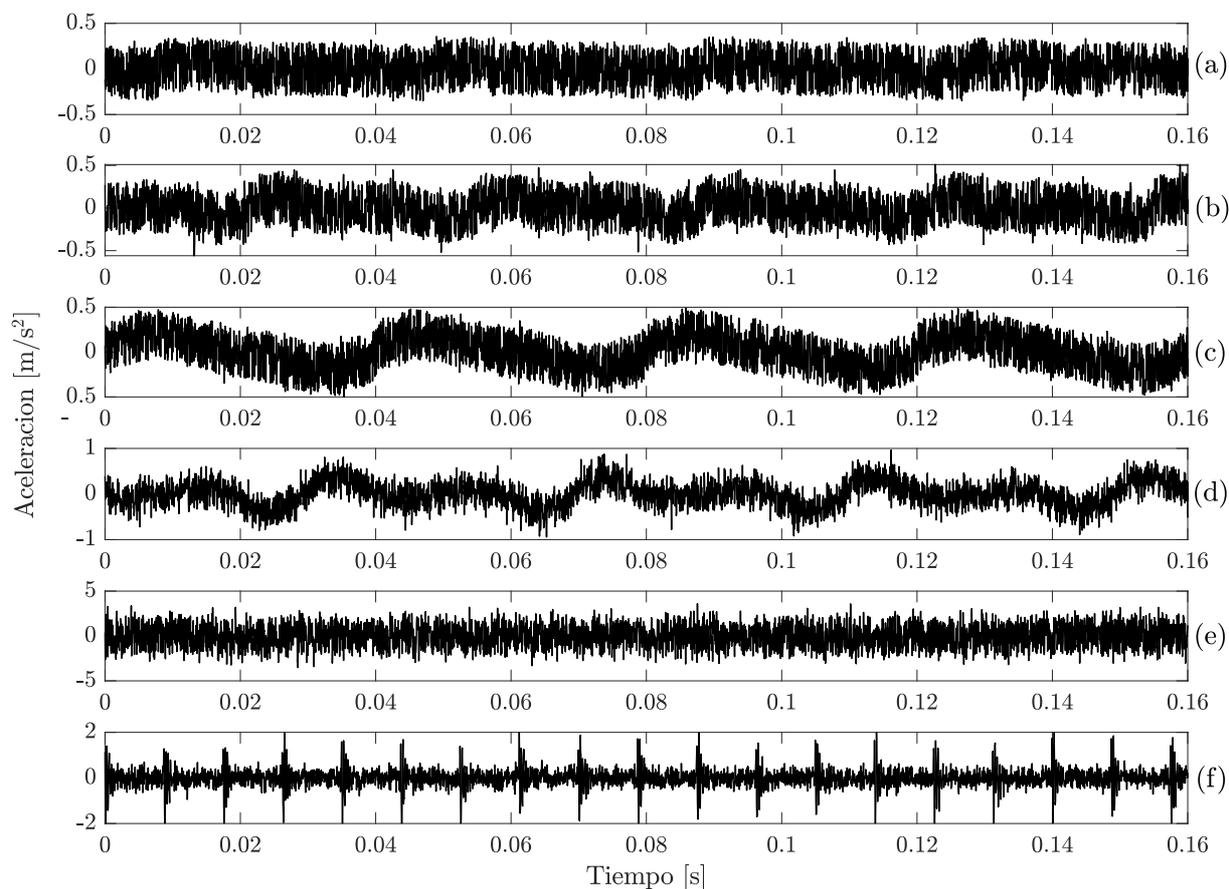


Figura 1: Señal representativa de una condición: (a) normal a 1500 rpm, (b) normal a 1800 rpm, (c) desbalance a 1500 rpm, (d) desalineación a 1500 rpm, (e) falta de lubricación a 1500 rpm y (f) falla de rodamiento a 1500 rpm.

2.2. Señales obtenidas experimentalmente

Este conjunto de datos se basa en MaFaulDa (Souza et al., 2021), la cual es una base de datos que incluye, entre otros elementos, 1941 registros temporales de aceleración obtenidos

sobre un simulador real de fallas (SpectraQuest's Machinery Fault Simulator). Además de la condición de funcionamiento normal, incorpora tres tipos de fallas con distintos niveles de daño: desbalanceo, desalineación y fallas en diversos componentes de rodamientos. Cada registro consta de seis señales de aceleración que corresponden a tres direcciones ortogonales medidas sobre dos cajas de rodamientos. La frecuencia de muestreo es de 50 kHz, con 250000 puntos por señal, y cada registro se obtuvo para velocidades de operación que varían entre 500 y 3600 rpm. La base de datos está disponible en https://www02.smt.ufrj.br/~offshore/mfs/page_01.html.

Para este trabajo, se seleccionaron señales considerando todas las condiciones de operación, pero limitadas a velocidades situadas entre 1500 y 1800 rpm. Con el propósito de compatibilizar las señales con las del conjunto sintético, se realizó un submuestro a una frecuencia de 24 kHz y cada señal resultante se dividió en otras 30. De esta manera, los registros de ambos sets poseen la misma cantidad de muestras. Además, de las seis señales de aceleración disponibles sólo se considera la de dirección radial de una de las dos cajas de rodamientos. En la Figura 2, se presenta una señal representativa para cada uno de los cinco tipos de condiciones.

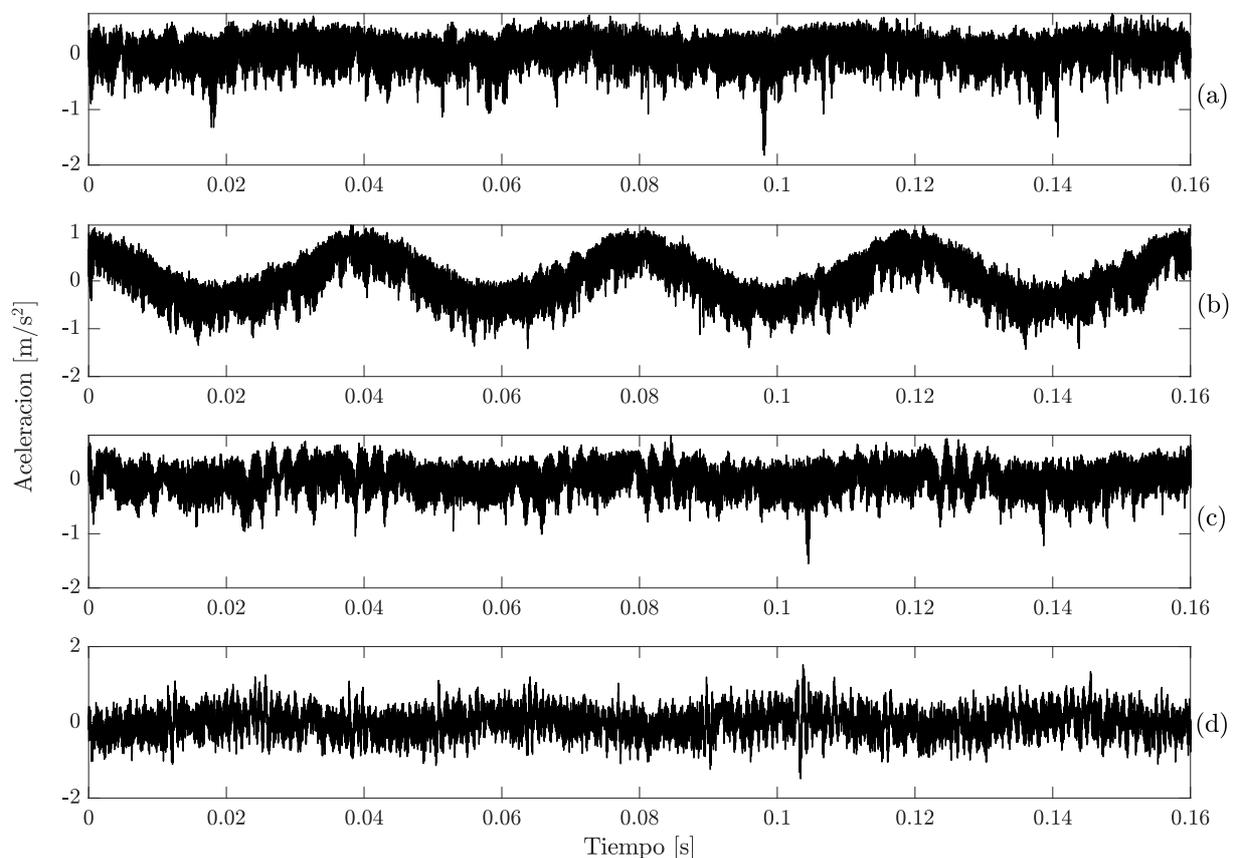


Figura 2: Señal representativa de una condición: (a) normal, (b) desbalanceo, (c) desalineación, (d) falla de rodamiento para una velocidad de 1500 rpm.

2.3. Combinación de los conjuntos de datos

El conjunto de datos empleado para el entrenamiento, validación y prueba de la red neuronal convolucional 1D propuesta resulta de combinar los dos sets de datos presentados anteriormente, lo cual produce un total de 7000 señales. Un resumen de sus características más importantes se detallan en la Tabla 1.

Condición	Etiqueta	Cantidad	Velocidad [rpm]	f_r [kHz]	Puntos
Normal	0	980	Entre 1500 y 1800	24	4096
Desbalance	1	1460	Entre 1500 y 1800	24	4096
Desalineación	2	2000	Entre 1500 y 1800	24	4096
Falla de rodamiento	3	2360	Entre 1500 y 1800	24	4096
Falta de lubricación	4	200	1500	24	4096

Tabla 1: Descripción del conjunto de datos.

3. DESCRIPCIÓN DE LA ARQUITECTURA PROPUESTA

En la Figura 3 se presenta la arquitectura de la red neuronal propuesta. Esta consiste de cinco capas convolucionales, seguidas por dos capas lineales completamente conectadas (fully connected), finalizando con una capa softmax que genera la distribución de probabilidades. Cada capa convolucional incluye una convolución 1D, acompañada de una normalización por lotes (batch normalization con parámetros entrenables) para mejorar el rendimiento, una función de activación ReLU y una capa de max pooling para reducir la dimensionalidad. En las capas lineales, se emplea la técnica de dropout para mitigar el sobreajuste. Las capas convolucionales tienen la función de extraer las características o patrones más relevantes de las señales utilizadas durante el entrenamiento, mientras que las capas lineales se encargan de realizar la clasificación. Los parámetros de las capas que componen esta arquitectura se detallan en la Tabla 2.

Nº	Capa	In channels	Out channels	Kernel (Size / Stride)	Padding
1	Convolutacional 1D	1	8	16×28	28
2	Max Pooling	8	8	2×2	0
3	Convolutacional 1D	8	64	3×1	1
4	Max Pooling	64	64	2×2	0
5	Convolutacional 1D	64	32	3×1	1
6	Max Pooling	32	32	2×2	0
7	Convolutacional 1D	32	64	3×1	1
8	Max Pooling	64	64	2×2	0
9	Convolutacional 1D	64	128	3×1	1
10	Max Pooling	128	128	2×2	0
		Neuronas			Dropout
11	Flatten	512			-
12	Lineal	128			0.3
13	Lineal	5			-
14	Softmax	5			-

Tabla 2: Parámetros característicos de la arquitectura implementada.

La arquitectura descrita anteriormente se implementó utilizando PyTorch. Para ajustar los parámetros entrenables (pesos sinápticos) de la red se adoptó como función de pérdida a la entropía cruzada y se eligió como optimizador al método de Adam. La tasa de aprendizaje (learning rate) de la red es constante e igual a 0.01. El tamaño de los minilotes de entrenamiento y el número de épocas se consideran variables.

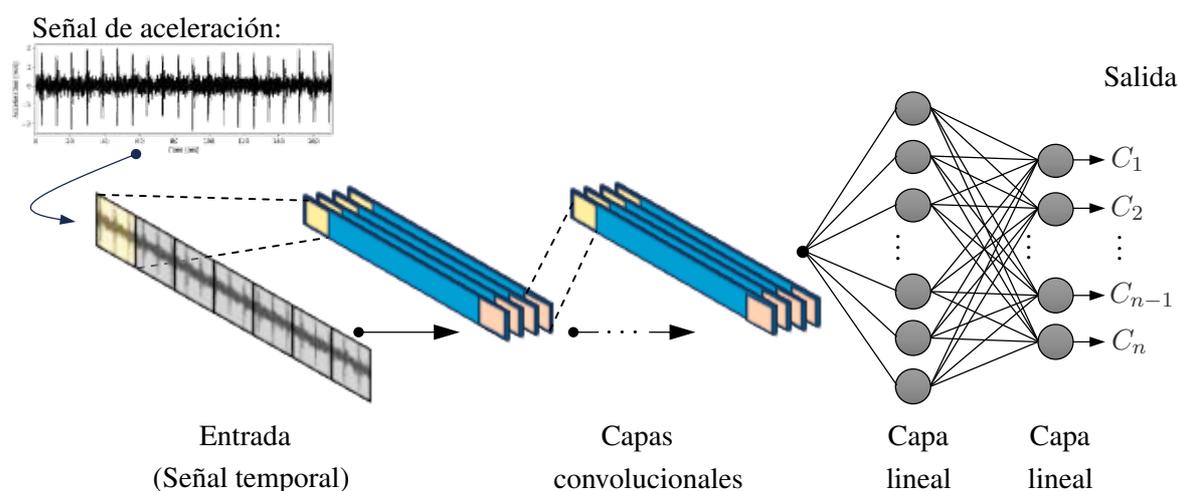


Figura 3: Estructura de la red neuronal convolucional 1D propuesta.

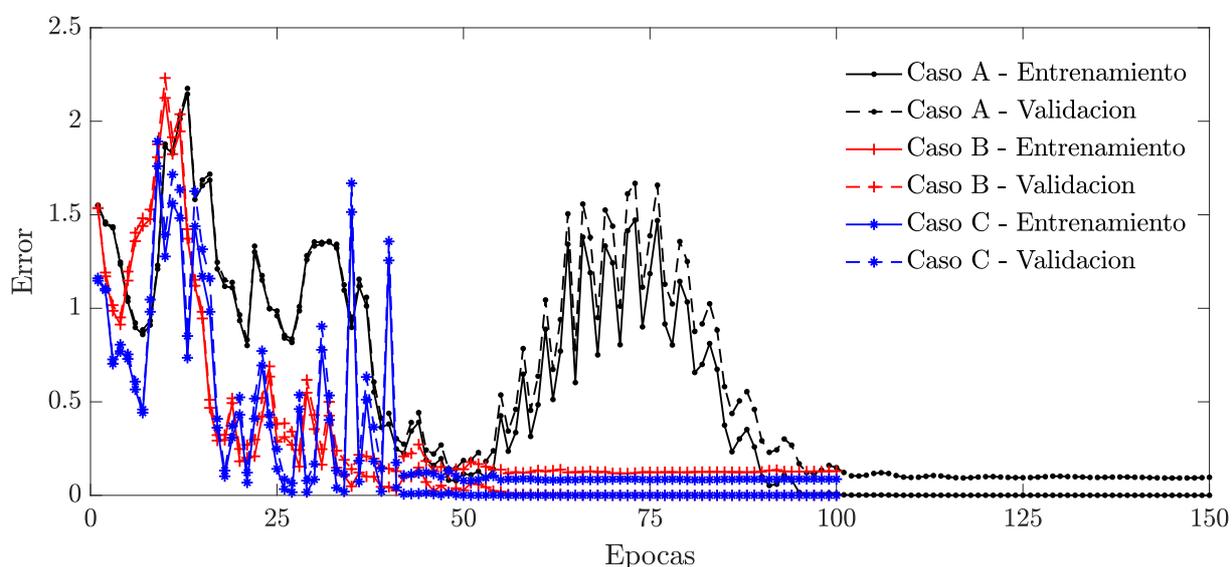


Figura 4: Error de entrenamiento y validación en función del número de épocas para los tres tamaños de minilotes considerados.

4. RESULTADOS Y DISCUSIONES

Previo a entrenar el modelo, el set de datos fue dividido en tres subconjuntos: entrenamiento, validación y prueba. El último de ellos está integrado por el 10 % de las señales disponibles. Del 90 % restante, el 80 % constituye el subconjunto de entrenamiento y el 20 % el de validación. Si bien las señales fueron seleccionadas aleatoriamente, se garantizó que la proporción de registros asociados a cada condición de funcionamiento fuera similar en todos los subconjuntos.

La red neuronal se entrenó utilizando minilotes de tres tamaños diferentes: 5040 (Caso A), 2520 (Caso B) y 1260 (Caso C). Para evaluar el desempeño del modelo, se analiza la evolución de los errores de entrenamiento y de validación junto con la accuracy a medida que transcurren las épocas de aprendizaje. Adicionalmente, se emplearon dos métricas complementarias, recall y precision, y la matriz de confusión. Debido a que se trata de una clasificación multiclase, las últimas dos métricas fueron calculadas ponderando la cantidad de señales por clase y obteniendo un promedio general.

En la Figura 4 se grafican el error de entrenamiento y de validación en función del número de

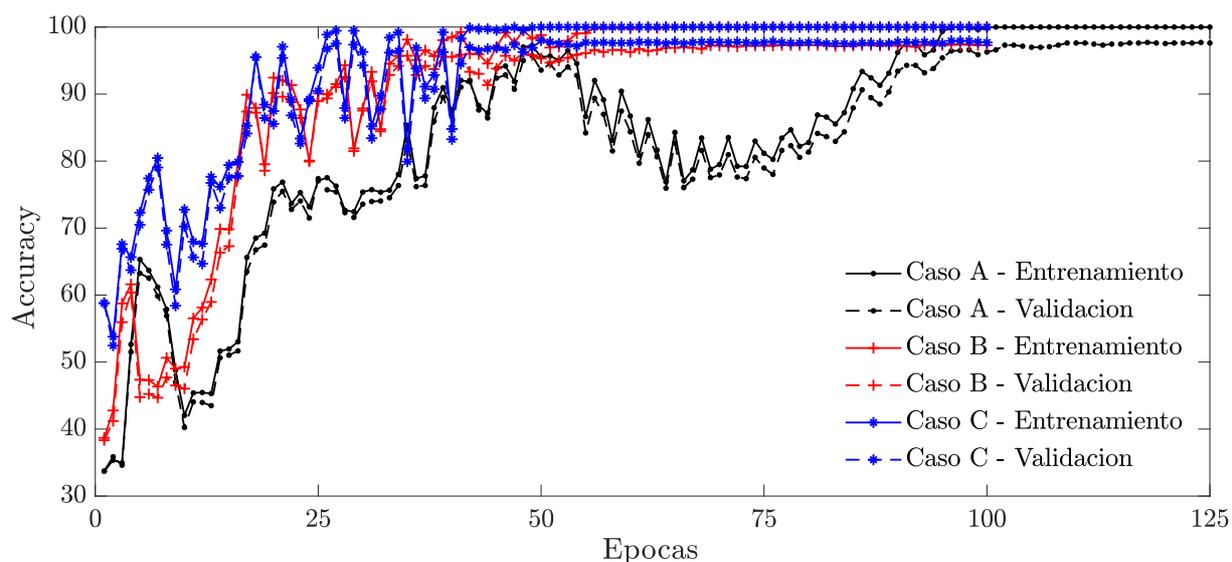


Figura 5: Accuracy para el conjunto de entrenamiento y validación en función del número de épocas para los tres tamaños de minilotes considerados.

Épocas	Caso	Entrenamiento			Validación		
		Accuracy	Precision	Recall	Accuracy	Precision	Recall
150	A	100	100	100	97.857	98.999	97.701
100	B	100	100	100	97.857	98.999	97.425
100	C	100	100	100	97.857	98.999	97.748

Tabla 3: Métricas obtenidas para los Casos A, B y C sobre el conjunto de entrenamiento y de validación.

épocas para los tres casos considerados. De acuerdo a lo observado, el error de entrenamiento para el Caso A presenta cierta oscilación alrededor de valores elevados cuando el número de épocas es inferior a 25, luego muestra una tendencia decreciente entre las 25 y 50 épocas. Posteriormente, crece hasta las 75 épocas alcanzando valores elevados y, finalmente decrece hasta estabilizarse en un valor próximo a cero. Puede notarse que el error de validación acompaña al de entrenamiento pero con valores ligeramente superiores. Por su parte, para los casos B y C el comportamiento observado es bastante similar. Cuando el número de épocas es inferior a 40, los errores de entrenamiento presentan fluctuaciones significativas. Sin embargo, los errores decrecen rápidamente hacia valores mínimos conforme aumenta el número de épocas. Comparativamente, se puede observar que el error de validación más bajo se obtiene con el Caso C y se logra con un número menor de épocas de entrenamiento.

Por otro lado, en la Figura 5 se grafica la evolución de la accuracy a medida que transcurren las épocas de entrenamiento. Según se observa, el comportamiento de estas curvas es opuesto al de las curvas de error. En el Caso A, la accuracy asociada al conjunto de entrenamiento muestra una tendencia creciente con el número de épocas hasta alcanzar un máximo local, luego decrece hasta un mínimo local cuando el número de épocas se ubica alrededor de las 70. Finalmente, se incrementa hasta estabilizarse en un valor próximo al 100%. Vale la pena notar que la accuracy del conjunto de validación converge a un valor ligeramente inferior al del conjunto de entrenamiento. Por su parte, las curvas de accuracy asociadas a los Casos B y C crecen oscilatoriamente conforme se incrementan las épocas de entrenamiento. Estas curvas convergen hacia valores próximos al 100% pero con un número de épocas menor al Caso A. Asimismo, a partir

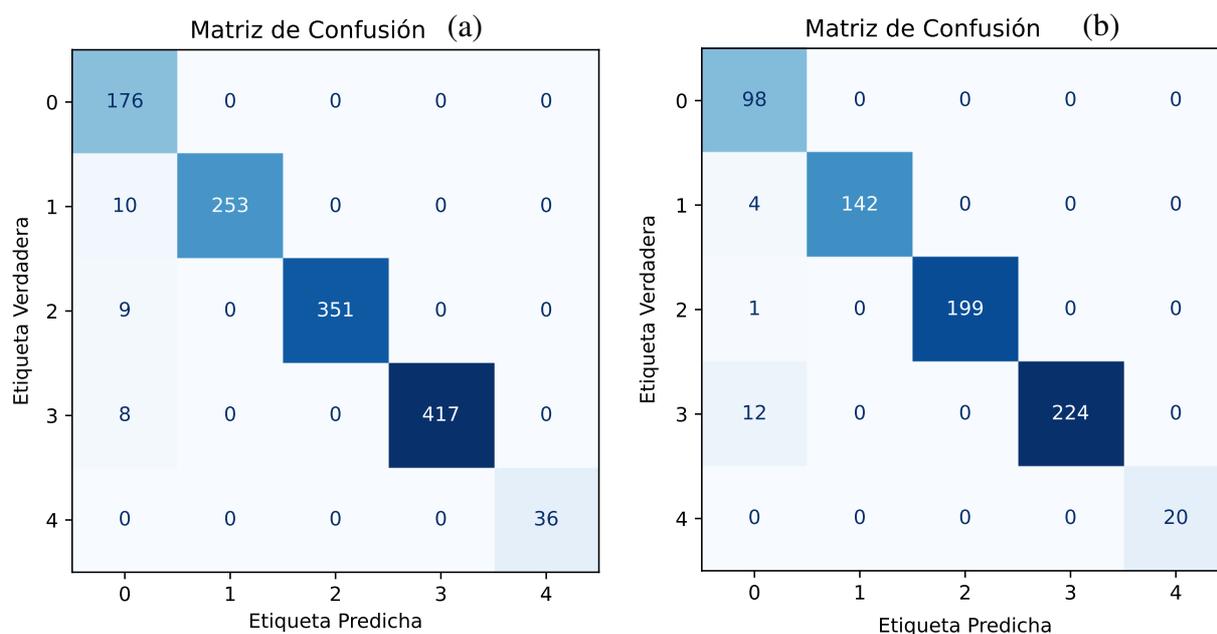


Figura 6: Matriz de confusión para: a) conjunto de validación sobre el Caso C con 100 épocas de entrenamiento, y b) conjunto de prueba sobre el Caso C con 45 épocas de entrenamiento.

de estas curvas se puede determinar la cantidad máxima de épocas de entrenamiento para evitar que el sobreajuste sea excesivo.

En la Tabla 3 se muestran las métricas obtenidas para los conjuntos de entrenamiento y de validación. Los valores de accuracy corresponden a los extraídos de las curvas de la Figura 5 en la última época de entrenamiento, mientras que los valores de precision y recall se calculan a partir de las matrices de confusión de cada caso. Desde el punto de vista de la clasificación de fallas, el escenario más crítico ocurre cuando la red clasifica una señal con falla como si perteneciera a una condición normal. El parámetro que refleja este comportamiento es el recall, lo que hace esencial obtener valores altos en esta métrica. De los tres casos analizados, el mayor valor de recall se obtiene con el Caso C. En la Figura 6a se presenta la matriz de confusión del Caso C para el conjunto de validación, en la cual se observa que la red en ocasiones confunde señales de desbalance, desalineación y falla de rodamiento con señales de condición normal.

Teniendo en cuenta que la red entrenada con 150 épocas (Caso A) o 100 épocas (Caso B y C) presentó sobreajuste, se decidió reentrenar la red para el Caso C (mejor recall) durante 45 épocas. Una vez entrenada, se clasificaron las señales del conjunto de prueba, cuyos resultados se muestran en la matriz de confusión de la Figura 6b. El valor de recall obtenido en este caso fue de 97.153 %. Es importante señalar que el error más relevante que comete la red es clasificar como normales señales que corresponden a fallas de rodamiento.

5. CONCLUSIONES

En este trabajo se propuso una red neuronal convolucional 1D para predecir el estado de condición de una máquina rotativa. La red fue entrenada y evaluada utilizando un conjunto de datos que combina señales sintéticas generadas computacionalmente con señales experimentales. Los resultados obtenidos muestran que la arquitectura propuesta es efectiva para la clasificación de fallas, logrando valores de accuracy y recall cercanos al 100 %.

Sin embargo, los resultados también evidencian la presencia de sobreajuste, fenómeno que se podría atribuir a factores como un número insuficiente de señales, la segmentación de señales

provenientes de un único registro, o una arquitectura excesivamente profunda. Para mitigar este problema y mejorar la eficiencia y capacidad de generalización del modelo, se abordarán estas cuestiones en trabajos futuros.

REFERENCIAS

- Alzghoul A., Jarndal A., Alsyouf I., Bingamil A.A., Ali M.A., y AlBaiti S. On the usefulness of pre-processing methods in rotating machines faults classification using artificial neural network. *Jornal of Applied and Computational Mechanics*, 7(1):254–261, 2021.
- Atmaja B.T., Ihsannur H., Suyanto, y Arifianto D. Lab-scale vibration analysis dataset and baseline methods for machinery fault diagnosis with machine learning. *Journal of Vibration Engineering & Technologies*, 12(2):1991–2001, 2024.
- Lei Y., Yang B., Jiang X., Jia F., Li N., y Nandi A.K. Applications of machine learning to machine fault diagnosis: A review and roadmap. *Mechanical systems and signal processing*, 138:106587, 2020.
- Liu R., Yang B., Zio E., y Chen X. Artificial intelligence for fault diagnosis of rotating machinery: A review. *Mechanical Systems and Signal Processing*, 108:33–47, 2018.
- Muszynska A. *Rotordynamics*. CRC press, 2005.
- Sinha J.K. *Industrial approaches in vibration-based condition monitoring*. CRC Press, 2020.
- Souza R.M., Nascimento E.G., Miranda U.A., Silva W.J., y Lepikson H.A. Deep learning for diagnosis and classification of faults in industrial rotating machinery. *Computers & Industrial Engineering*, 153:107060, 2021.
- Zhao R., Yan R., Chen Z., Mao K., Wang P., y Gao R.X. Deep learning and its applications to machine health monitoring. *Mechanical Systems and Signal Processing*, 115:213–237, 2019.
- Zhu Z., Lei Y., Qi G., Chai Y., Mazur N., An Y., y Huang X. A review of the application of deep learning in intelligent fault diagnosis of rotating machinery. *Measurement*, 206:112346, 2023.