

## DETECCIÓN DEL ESTADO DE FALLA EN MÁQUINAS A PARTIR DE VIBRACIONES MECÁNICAS CON TÉCNICAS DE APRENDIZAJE AUTOMÁTICO

### MACHINERY FAULTS DETECTION BASED ON MECHANICAL VIBRATIONS WITH MACHINE LEARNING TECHNIQUES

Martín E. Pérez Segura<sup>a,b</sup>, Emmanuel Beltramo<sup>a,b</sup>, Agostina C. Aichino<sup>a,b</sup>, Santiago Ribero<sup>a,b</sup> y Sergio Preidikman<sup>a,b</sup>

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

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

**Palabras clave:** Aprendizaje automático, detección de fallas, vibraciones en maquinaria.

**Resumen.** El análisis de vibraciones mecánicas es un proceso ampliamente utilizado para la detección de fallas en maquinarias. En su enfoque tradicional, este método requiere de la participación de un analista experimentado para interpretar los resultados y sintonizar el proceso de acuerdo al caso de aplicación. Las nuevas tecnologías de aprendizaje automático que incorporan sistemas de detección inteligente basados en redes neuronales han permitido reducir la participación del analista en este proceso. En este trabajo, se presentan tres arquitecturas de redes neuronales diseñadas para detectar fallas a partir de señales de vibraciones: i) una red feed forward; ii) una red convolucional 1D; y, iii) una red convolucional 2D. Las tres arquitecturas son entrenadas con un set de señales sintéticas y experimentales provenientes de sistemas en condiciones de funcionamiento normal y anormal, y se evalúa comparativamente su capacidad para detectar dichas condiciones de funcionamiento. Los resultados muestran un potencial prometedor de estas arquitecturas para cumplir de forma eficiente su objetivo.

**Keywords:** Machine learning, failure detection, vibrations, industrial machinery.

**Abstract.** The analysis of mechanical vibrations is a widely used technique for failure detection in industrial machinery. The traditional approach requires a wide expertise to interpret the results and tune the procedure according to each application. However, new machine learning technologies that incorporate neuronal-network-based systems have reduced the participation of analysts in damage detection. In this work, three neural network architectures designed to detect faults from vibration signals are presented: i) a feed-forward network; ii) a 1D convolutional network; and, iii) a 2D convolutional network. The three architectures are trained with sets of synthetic and experimental signals representing systems in normal and abnormal operation conditions, and their ability to detect these conditions is comparatively evaluated. The results show the potential of these systems to efficiently achieve their objective.

## 1. INTRODUCCIÓN

En su tradicional libro, J. Taylor (Taylor, 2003) expresa que el análisis de vibraciones es la mejor alternativa que tienen las compañías industriales que trabajan con maquinaria rotativa pesada para ahorrar dinero (...), ya que pueden evitar reparar equipamiento en buen funcionamiento, mejorar la calidad de los repuestos, predecir fallas inminentes y reducir los tiempos de parada. Más adelante, en la misma obra se lee "*el diagnóstico preciso de problemas en maquinaria rotativa requiere un exhaustivo entendimiento de la señal en el dominio del tiempo y el espectro en el dominio de la frecuencia*". El extracto anterior es un ejemplo que coincide con varios otros que se encuentran en la bibliografía relacionada y resalta dos aspectos fundamentales del análisis de vibraciones de máquinas: su importancia en la industria, y la necesidad de una amplia formación y experiencia en el área para poder realizarlo.

Más específicamente, el diagnóstico de máquinas es una técnica para detectar, aislar e identificar fallas a partir de información sobre sus condiciones de operación. Esta técnica consta de tres tareas básicas (Liu et al., 2018): i) determinar si el equipo opera de forma normal o no; ii) encontrar fallas incipientes y sus causas; iii) predecir la tendencia de desarrollo de una falla.

En la última década, los sistemas inteligentes se han incorporado progresivamente en cada vez más aspectos de los procesos industriales (Belfiore y Rudas, 2014) y la detección de estados de falla o mal funcionamiento en máquinas no es la excepción (Liu et al., 2018). En efecto, el paradigma de la Industria 4.0 requiere de forma casi mandatoria la incorporación de tecnologías digitales avanzadas relacionadas con la inteligencia artificial y la ciencia de datos (Mourtzis et al., 2022), para construir un ecosistema inteligente e interconectado para monitoreo en tiempo real, mantenimiento preventivo y procesos productivos más eficientes y flexibles.

La aplicación de sistemas inteligentes basados en aprendizaje automático a la detección de fallas en maquinarias tiene por finalidad la automatización del diagnóstico y la reducción de la participación de analistas especializados en el proceso. De entre los modelos basados en datos que son aptos para este propósito los más habitualmente utilizados se construyen con máquinas de soporte vectorial (Atmaja et al., 2024) (SVM, por sus siglas en inglés), árboles de decisión (Kumar et al., 2023), y redes neuronales (NN, por sus siglas en inglés).

La aplicación de redes neuronales para la detección de fallas en maquinaria ha sido explorada en la literatura (Sepulveda y Sinha, 2020). Por sus características, las redes neuronales pre-alimentadas (FFNN, por *Feed-forward Neuronal Network* en inglés) (Vrba et al., 2021) y las redes neuronales convolucionales en una y dos dimensiones (1DCNN y 2DCNN, por *1D Convolutional Neuronal Network* y *2D Convolutional Neuronal Network* en inglés) (Zhang et al., 2020) son las candidatas más adecuadas para esta tarea. Generalmente, el diseño de una red neuronal para detección de fallas se enfoca en tipos particulares de mal funcionamientos como falta de lubricación, desbalanceos o desalineaciones, o en componentes específicos como rodamientos o cajas de engranajes.

En este trabajo se hace foco en la primera de las tareas que conciernen al diagnóstico de máquinas: determinar si el equipo opera de forma normal o no. Por lo tanto, se presentan tres arquitecturas de redes neuronales que funcionan como clasificadores binarios y están diseñadas para detectar el estado de funcionamiento normal (FN) o funcionamiento anormal (FA) a partir de señales de vibraciones. La primera arquitectura es una red neuronal de tipo feed forward (FFNN) que utiliza como dato de entrada una señal de aceleración en el dominio del tiempo. La segunda es una red convolucional 1D que también utiliza una señal de aceleración en el dominio del tiempo. Por último, se presenta una red convolucional 2D que opera sobre espectrogramas construidos a partir de la señal de aceleración. Las tres arquitecturas son entrenadas con un set

de señales sintéticas y experimentales, y se evalúa comparativamente su capacidad para detectar dichas condiciones de funcionamiento.

## 2. LOS DATOS

El componente fundamental para el desarrollo de cualquier sistema inteligente basado en redes neuronales es el conjunto de datos que sirve como sustento para el aprendizaje. En este trabajo, se emplea un conjunto de datos mixto que contiene señales generadas computacionalmente (sintéticas) y señales medidas en maquinaria de laboratorio (experimentales). El proceso de sintetización de datos consiste en utilizar la topología típica que se observa en las mediciones de vibraciones de máquinas con fallas habituales para construir señales en el dominio del tiempo que simulen tales mediciones. Las señales experimentales, por su parte, provienen de investigaciones realizadas sobre dispositivos de laboratorio instrumentados para relevar señales y utilizarlas con diversos fines, específicamente del trabajo de [Ribeiro \(2022\)](#).

De acuerdo al objetivo del presente trabajo, todas las señales consideradas se dividen en dos grupos: señales correspondientes a funcionamientos normales (FN) y señales correspondientes a funcionamientos anormales (FA). Además, los datos de las señales corresponden a aceleraciones en el dominio del tiempo.

### 2.1. Señales generadas computacionalmente

Este conjunto contiene en total 1600 señales que fueron generadas con una frecuencia de muestreo ( $f_r$ ) de 24 kHz y 4096 puntos. De todas las señales, la mitad (800 señales) corresponde a FN y las restantes (800 señales), a FA. Las señales de FN están asociadas a velocidades constantes de operación de 1500 rpm y 1800 rpm, mientras que todas las señales de FA están asociadas a una velocidad de operación constante de 1500 rpm. Además, para producir las señales de FA se consideraron cuatro causas: desbalanceo (200 señales), desalineación (200 señales), falta de lubricación (200 señales) y falla de rodamiento (200 señales).

### 2.2. Señales obtenidas experimentalmente

Como se mencionó, el conjunto de señales obtenidas experimentalmente proviene del trabajo de [Ribeiro \(2022\)](#): la base de datos MaFaulDa. Esta base de datos incluye una gran cantidad de señales de aceleración medidas en el dominio del tiempo a partir de un simulador real de fallas (SpectraQuest's Machinery Fault Simulator). Además de la condición de FN, este dispositivo es capaz de simular tres condiciones de FA, con distintos niveles de daño: desbalanceo, desalineación y fallas en rodamientos. Cada registro se compone de seis señales de aceleración medidas sobre dos cajas de rodamientos en tres direcciones ortogonales. Todas las señales fueron relevadas con una frecuencia de muestreo de 50 kHz, y cuentan con 250000 puntos. En cuanto a las velocidades de operación del simulador, en la base de datos se encuentran disponibles registros que van de las 500 rpm a las 3600 rpm.

Con el objetivo de guardar consistencia con las señales sintéticas, de la base de datos se seleccionaron señales experimentales con velocidades de operación situadas entre 1500 y 1800 rpm y se realizó un submuestro a una frecuencia de 24 kHz. Asimismo, cada señal resultante se subdividió para balancear la cantidad de muestras. En la Figura 1, se presentan ejemplos de señales para cada uno de los casos mencionados.

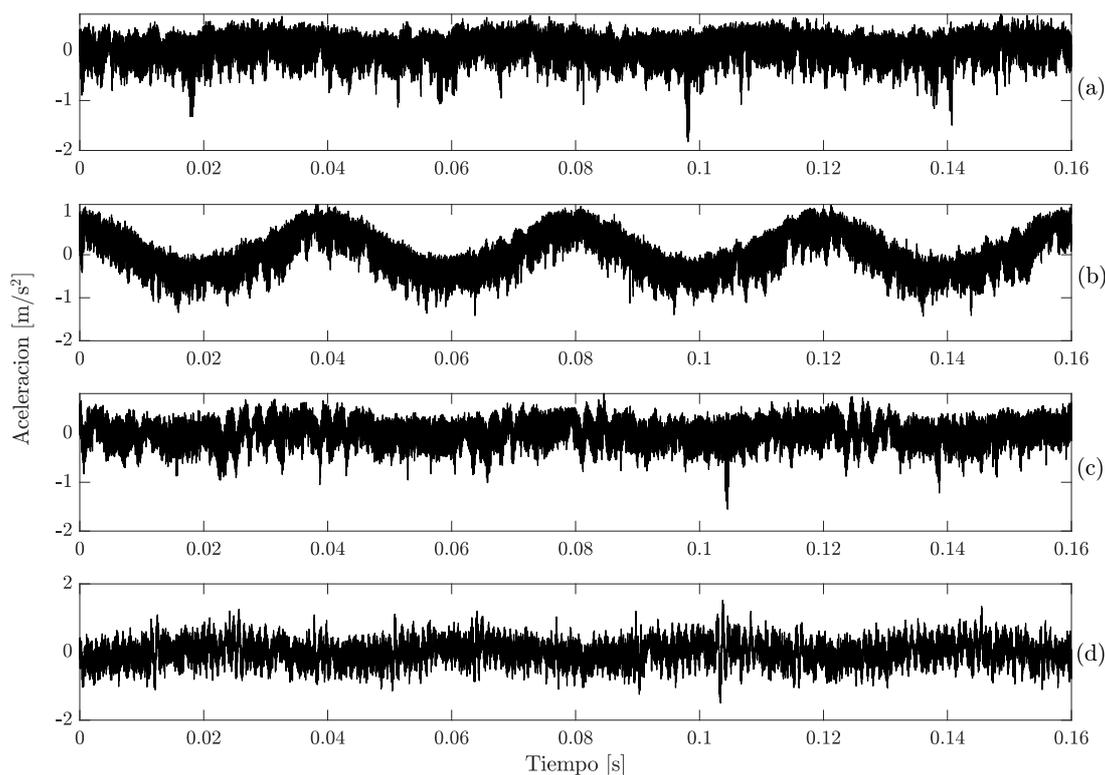


Figura 1: Ejemplos de señales experimentales: (a) normal a 1500 rpm; (b) anormal (desbalance a 1500 rpm); (c) anormal (desalineación a 1500 rpm); (d) anormal (falla de rodamiento a 1500 rpm).

### 2.3. El conjuntos de datos

De la combinación de los casos anteriores se obtiene el conjunto de datos finalmente utilizado. En la Tabla 1 se resumen las características más relevantes del conjunto de datos.

Condición	Causa	Cantidad	Velocidad [rpm]	$f_r$ [kHz]	Tamaño
Normal (id=0)	Ninguna	980	Entre 1500 y 1800	24	4096
Anormal (id=1)	Desbalance	1460	Entre 1500 y 1800	24	4096
	Desalineación	2000	Entre 1500 y 1800	24	4096
	Falla de rodamiento	2360	Entre 1500 y 1800	24	4096
	Falta de lubricación	200	1500	24	4096

Tabla 1: Descripción del conjunto de datos.

## 3. ARQUITECTURAS EVALUADAS

Las arquitecturas de los tres clasificadores binarios de señales se detallan a continuación. Como se mencionó, corresponden a una FFNN, una 1DCNN y una 2DCNN.

### 3.1. Red neuronal feed forward

La arquitectura Feed Forward es la más simple de las evaluadas y cuenta con siete capas completamente conectadas de neuronas (*fully connected*), como se esquematiza en la Figura 2. Como dato de entrada, la red toma la señal de aceleración en el dominio del tiempo por lo que en su primera *capa lineal* cuenta con tantas neuronas como puntos tiene la señal (4096). La

segunda capa de la red (la *capa ReLU*) cuenta con 1024 neuronas con funciones de activación ReLU. Luego, la red cuenta con una *capa dropout* con un factor de dilución  $p = 0,5$ . A partir de la cuarta capa, la secuencia lineal-ReLU-dropout se repite utilizando 64 neuronas en la *capa lineal* y nuevamente  $p = 0,5$ . Finalmente, la capa de salida es una capa lineal de dos neuronas que clasifican la señal en los dos estados posibles: FN y FA.

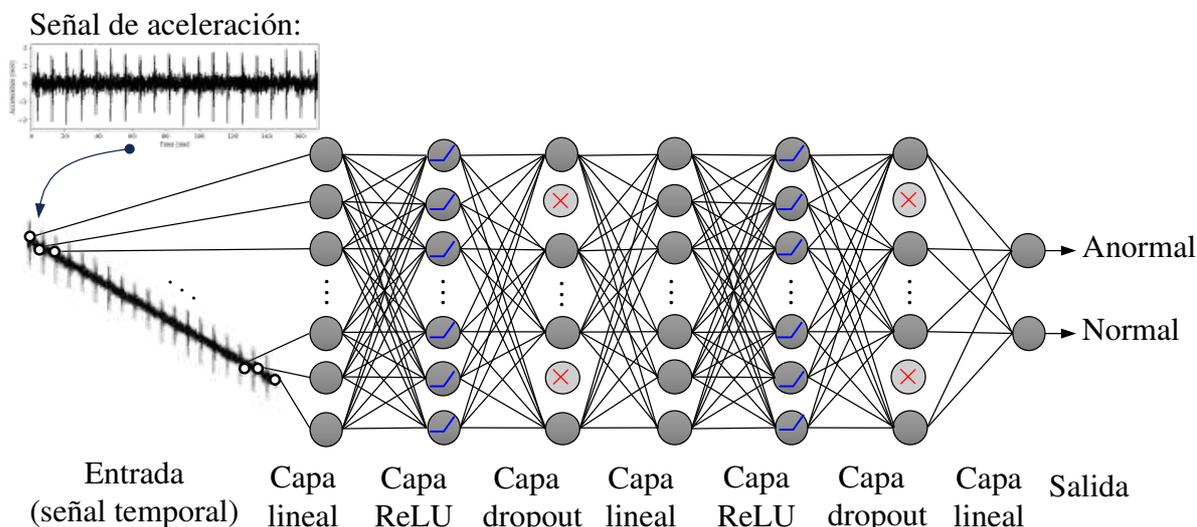


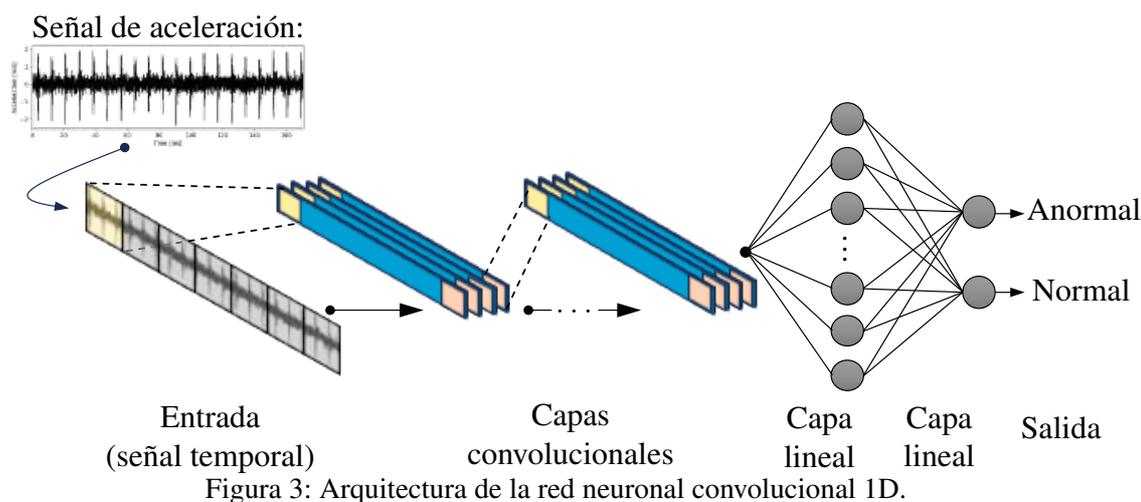
Figura 2: Arquitectura de la red neuronal Feed Forward.

### 3.2. Red convolucional 1D

La arquitectura de la red convolucional en una dimensión está compuesta por cinco capas convolucionales y cuatro capas lineales completamente conectadas (*fully connected*), y utiliza como entrada la señal de aceleración en el dominio del tiempo. Todas las capas convolucionales tienen la misma estructura con la siguiente secuencia: una convolución, una normalización por lotes (*batch normalization*), una función de activación ReLU y un *max pooling*. Antes de pasar a las capas lineales, se efectúa una operación de *flatten* para convertir las variables tensoriales en vectores. La secuencia de capas lineales utilizadas es la siguiente: una capa lineal de 128 neuronas, una capa de normalización por lotes (*batch normalization*), una capa con funciones de activación ReLU, una capa de salida con dos neuronas que clasifican la señal en los dos estados posibles: FN y FA. En la Figura 3 se esquematiza la arquitectura de la red, mientras que los parámetros de las capas que la componen se detallan en la Tabla 2.

### 3.3. Red convolucional 2D

La arquitectura de la red convolucional en dos dimensiones está compuesta por dos capas convolucionales bidimensionales y cuatro capas lineales completamente conectadas (*fully connected*). La estructura interna de todas estas capas es idéntica a las del modelo 1D. Sin embargo, en este caso, la entrada de la red la constituye un espectrograma construido a partir de la señal de aceleración con ventanas de 64 puntos, utilizando el tiempo como variable en la primera dimensión y la frecuencia en la segunda (Islam y Kim, 2018). Los parámetros de las capas que componen la arquitectura se detallan en la Tabla 3, mientras que en la Figura 4 se esquematiza la arquitectura descrita.



Nº	Capa	In channels	Out channels	Kernel (Size / Stride)	Padding
1	Convolutacional 1D	1	8	$16 \times 28$	28
2	Max Pooling	8	8	$2 \times 2$	0
3	Convolutacional 1D	8	64	$3 \times 1$	1
4	Max Pooling	64	64	$2 \times 2$	0
5	Convolutacional 1D	64	32	$3 \times 1$	1
6	Max Pooling	32	32	$2 \times 2$	0
7	Convolutacional 1D	32	64	$3 \times 1$	1
8	Max Pooling	64	64	$2 \times 2$	0
9	Convolutacional 1D	64	128	$3 \times 1$	1
10	Max Pooling	128	128	$2 \times 2$	0
		<b>Neuronas</b>			<b>Dropout</b>
11	Flatten		512		-
12	Lineal		128		0.5
13	Lineal		2		-

Tabla 2: Parámetros de la arquitectura de la red convolucional 1D. Por simplicidad, las capas de normalización por lotes y ReLU no fueron incorporadas.

#### 4. ENTRENAMIENTO DE LOS MODELOS

Luego de diseñar e implementar los modelos de clasificación, se los somete al proceso de entrenamiento. Para realizar este proceso, el conjunto de datos se divide de forma aleatoria y conservando la proporción de cada tipo y fuente (experimental y sintética) de las señales en tres grupos disjuntos según el detalle de la Tabla 4: de entrenamiento, de validación y de testeo.

Durante el entrenamiento, se realizan 50 o 75 épocas, según la arquitectura, y en cada una se presentan a cada red neuronal todas las señales del grupo de entrenamiento y se evalúa su performance con las señales del grupo de validación. Luego de cada época se calcula el error sobre cada grupo de señales y se recalculan las variables del modelo. La evolución de cada modelo durante el proceso de aprendizaje se presenta en la Figura 5, la Figura 6 y la Figura 7.

La Figura 5 muestra que, el error sobre el conjunto de entrenamiento de la arquitectura feed forward disminuye progresivamente y de manera sostenida. El error sobre el conjunto de validación, en cambio, luego de una disminución inicial, presenta oscilaciones a partir de la época 40. Este fenómeno suele relacionarse con el sobreajuste (*overfitting*).

Nº	Capa	In channels	Out channels	Kernel (Size / Stride)	Padding
1	Convolutacional 2D	1	8	$8 \times 1$	0
2	Max Pooling	8	8	$2 \times 2$	0
3	Convolutacional 2D	8	64	$4 \times 1$	0
4	Max Pooling	64	64	$2 \times 2$	0
<b>Neuronas</b>					<b>Dropout</b>
5	Flatten	9216			-
6	Lineal	128			0.5
7	Lineal	2			-

Tabla 3: Parámetros de la arquitectura de la red convolutacional 2D. Por simplicidad, las capas de normalización por lotes y ReLU no fueron incorporadas.

Grupo de datos	Porcentaje del total	Cantidad de señales
Entrenamiento	72 %	5048
Validación	18 %	1260
Testeo	10 %	700
Total	100 %	7000

Tabla 4: Subdivisión del conjunto de datos para el entrenamiento.

El proceso de entrenamiento de la red convolutacional 1D que se resume en la Figura 6 muestra dos etapas de oscilaciones, una al inicio y otra alrededor de la época 20. Luego de estos cambios, ambos errores se sostienen de forma casi constante a lo largo de las épocas con muy poca diferencia entre ellos. Nuevamente, este tipo de comportamientos suele estar relacionado con el sobreajuste (*overfitting*).

Por último, la Figura 7 muestra que el proceso de entrenamiento de la red convolutacional 2D es algo más complejo. A pesar de que ambos errores se mantienen próximos entre sí, su evolución es algo inestable. Mientras las épocas avanzan, se observan tres etapas (alrededor de la época 20, la 40 y la 60) en las que los errores parecen estabilizarse, pero que son interrumpidas por crecimientos abruptos seguidos de oscilaciones. Pasadas estas etapas, parecería obtenerse un error relativamente bajo y constante.

## 5. RESULTADOS

Luego de concluidas todas las épocas de entrenamiento, se utiliza el conjunto de testeo para evaluar la performance final de cada modelo. Los resultados obtenidos se presentan en dos formatos, el primero de ellos se encuentra en la Tabla 5 y corresponde a los puntajes (*scores*) de testeo exactitud (*accuracy*), precisión (*precision*) y exhaustividad (*recall*). El segundo formato muestra los resultados en matrices de confusión (Figura 8) donde se compara la etiqueta verdadera (FN = 0 y FA = 1) con la etiqueta predicha por el modelo en cada caso.

Todos los resultados, tanto los de los representados por los puntajes como los mostrados en las matrices de confusión, indican un buen nivel de performance de todas las arquitecturas en lo que respecta a la detección del tipo de funcionamiento de una máquina basado en una señal de vibración. No obstante, la casi inexistente presencia de errores en las predicciones indica algún nivel de sobreajuste de los modelos, tal y como se observó en el proceso de entrenamiento.

Detalle capa convolucional:

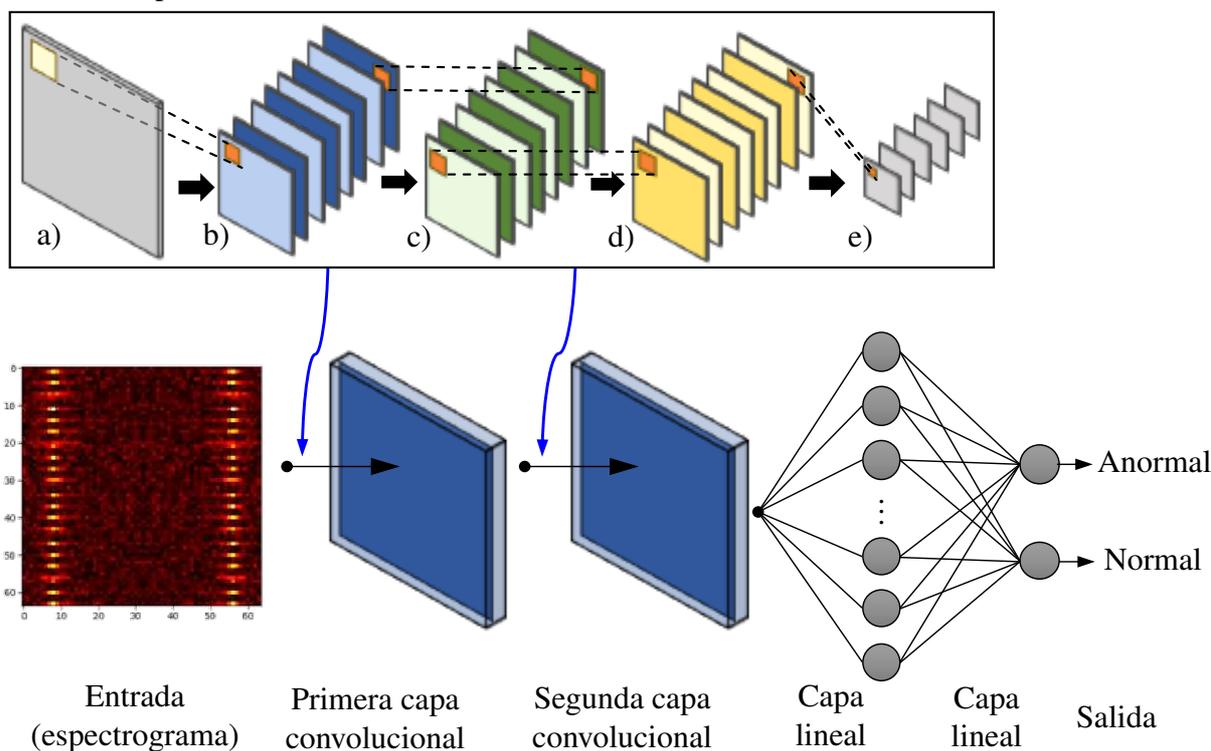


Figura 4: Arquitectura de la red neuronal convolucional 2D. Detalle: a) entrada, b) capa convolucional 2D, c) capa de normalización por lotes, d) capa ReLU, e) capa *max pooling*.

Arquitectura	Puntajes		
	Accuracy	Precision	Recall
Feed Forward	98.71 %	100 %	98.51 %
Convolutacional 1D	100 %	100 %	100 %
Convolutacional 2D	100 %	100 %	100 %

Tabla 5: Resultados obtenidos con cada arquitectura sobre el conjunto de testeo.

## 6. CONCLUSIONES

En este trabajo se presentaron tres arquitecturas de redes neuronales que funcionan como clasificadores binarios y están diseñadas para detectar el estado de funcionamiento normal (FN) o funcionamiento anormal (FA) a partir de señales de vibraciones: i) una red neuronal feed forward; ii) una red neuronal convolucional 1D; y iii) una red convolucional 2D. Las tres arquitecturas fueron entrenadas con un set de señales sintéticas y experimentales, y las evaluaciones realizadas sobre el cumplimiento de su objetivo de diseño fueron satisfactorias.

A pesar de que los resultados obtenidos son alentadores, no puede dejar de notarse la presencia del fenómeno de sobreajuste de los modelos que, debido a la gran similitud entre las señales que integran los conjuntos de validación y entrenamiento, produce métricas casi perfectas. Las causas de este fenómeno serán atacadas en futuros trabajos con el objetivo de mejorar las prestaciones de estos sistemas. Asimismo, la extracción de características en una etapa de pre-procesamiento de las señales constituye una alternativa interesante para investigar en el futuro.

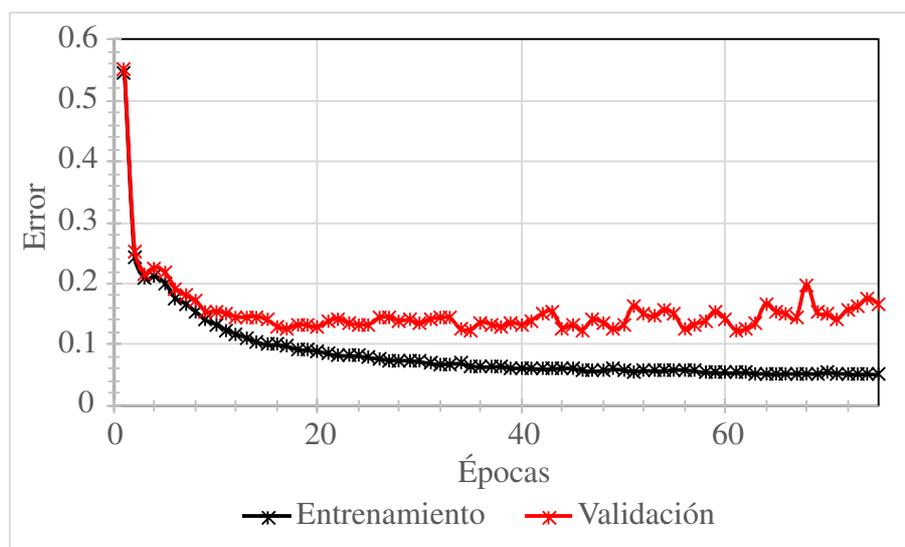


Figura 5: Evolución de los errores de la red Feed Forward durante el entrenamiento.

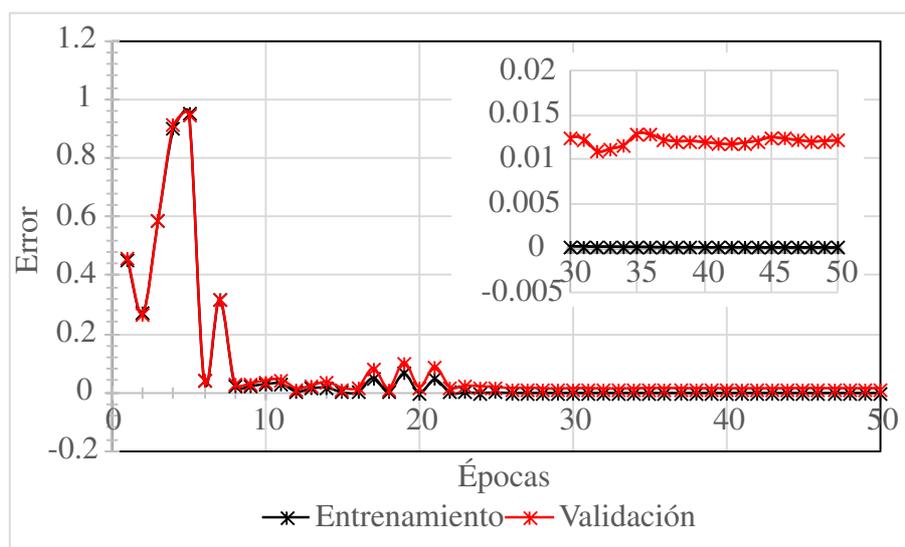


Figura 6: Evolución de los errores de la red Convolutiva 1D durante el entrenamiento.

## REFERENCIAS

- 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.
- Belfiore N.P. y Rudas I.J. Applications of computational intelligence to mechanical engineering. páginas 351–368, 2014. doi:10.1109/CINTI.2014.7028702.
- Islam M.M. y Kim J.M. Motor bearing fault diagnosis using deep convolutional neural networks with 2d analysis of vibration signal. En *Advances in Artificial Intelligence: 31st Canadian Conference on Artificial Intelligence, Canadian AI 2018, Toronto, ON, Canada, May 8–11, 2018, Proceedings 31*, páginas 144–155. Springer, 2018.
- Kumar S., Kumar V., Sarangi S., y Singh O.P. Gearbox fault diagnosis: A higher order moments approach. *Measurement*, 210:112489, 2023. ISSN 0263-2241. doi:https://doi.org/10.1016/j.measurement.2023.112489.

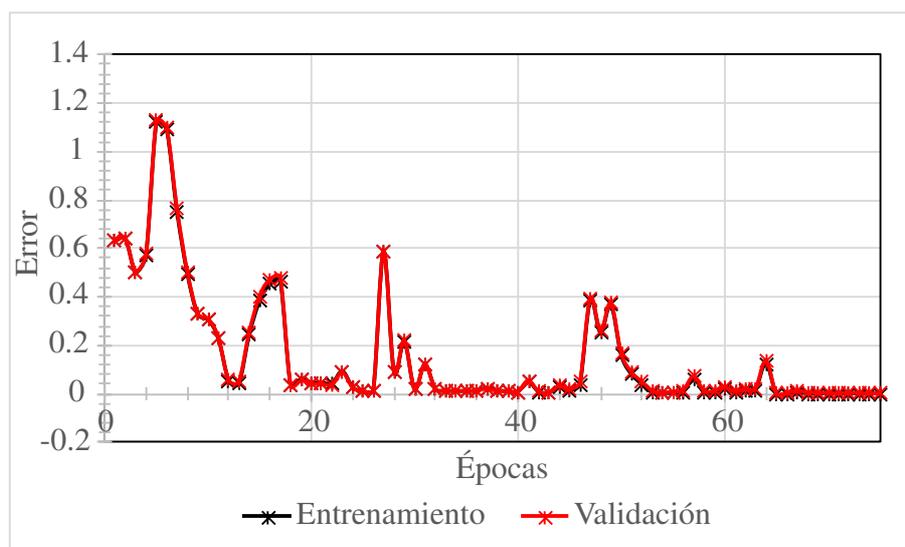


Figura 7: Evolución de los errores de la red Convolutiva 2D durante el entrenamiento.

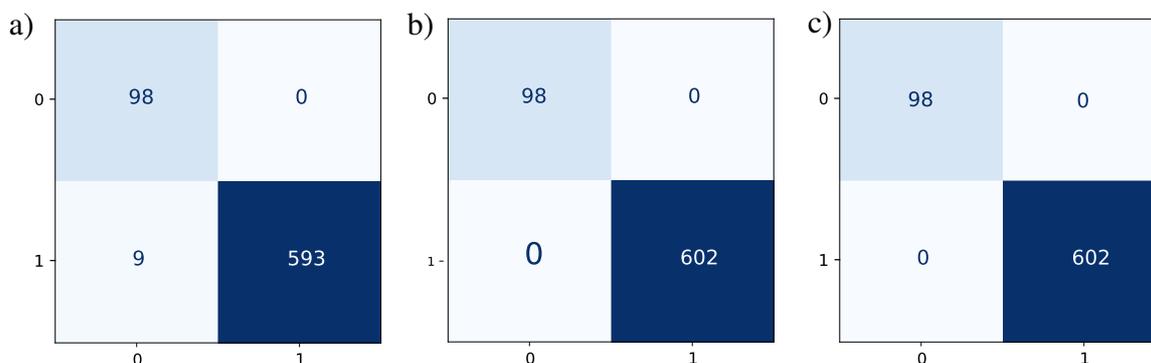


Figura 8: Matrices de confusión obtenidas con cada arquitectura sobre el conjunto de testeo. a) Feed Forward, b) Convolutiva 1D, c) Convolutiva 2D.

- 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.
- Mourtzis D., Angelopoulos J., y Panopoulos N. A literature review of the challenges and opportunities of the transition from industry 4.0 to society 5.0. *Energies*, 15(17), 2022. ISSN 1996-1073. doi:10.3390/en15176276.
- Ribeiro F. Machinery fault database (mafaulda)-multivariate time-series acquired by sensors on a spectraquest's machinery fault simulator (mfs) alignment-balance-vibration (abvt). 2022.
- Sepulveda N.E. y Sinha J. Parameter optimisation in the vibration-based machine learning model for accurate and reliable faults diagnosis in rotating machines. *Machines*, 8(4):66, 2020.
- Taylor J. *The Vibration Analysis Handbook: A Practical Guide for Solving Rotating Machinery Problems*. VCI, 2003. ISBN 9780964051720.
- Vrba J., Cejnek M., Steinbach J., y Krbcova Z. A machine learning approach for gearbox system fault diagnosis. *Entropy*, 23(9), 2021. ISSN 1099-4300.
- Zhang J., Yi S., Liang G., Hongli G., Xin H., y Hongliang S. A new bearing fault diagnosis method based on modified convolutional neural networks. *Chinese Journal of Aeronautics*, 33(2):439–447, 2020.