

Artificial Intelligence for the Prediction of Bearing Failures in Industrial Machines Based on Data Entry: A Systematic Review of the Literature

Leonel Alfredo Gamero Cardenas¹, Paul Adrián Melo Medina¹, Gerby Giovanna Rondán Sanabria, PhD¹

¹Universidad Tecnológica del Perú, Arequipa – Perú, U18303362@utp.edu.pe, U19204560@utp.edu.pe, grondan@utp.edu.pe.

Abstract– Artificial intelligence in the field of predictive maintenance is becoming increasingly prominent, especially for identifying problems in industrial machinery bearings. The objective of this RSL is to show the most effective artificial intelligence-based methods for the analysis of various bearing failures. In the methodology, a manual search of original articles was carried out in Scopus, obtaining 295 in total, of which 55 studies met the established inclusion criteria. The application of artificial intelligence for problem identification reduces the costs associated with bearing failures, and greatly increases the effectiveness in fault detection. Finally, the methods with the highest efficiency included in this RSL were: the neural network method based on an initial block capsule network (ICN) and the refined composite multiscale dispersion entropy method (RCMDE.) with an efficiency of 100 % respectively.

Keywords– Artificial Intelligence – Bearings – Fails – Diagnostic.

Digital Object Identifier: (only for full papers, inserted by LACCEI).
ISSN, ISBN: (to be inserted by LACCEI).
DO NOT REMOVE

Inteligencia Artificial para la Predicción de Fallas en Rodamientos de Máquinas Industriales Basada en el Ingreso de Datos: Una Revisión Sistemática de la Literatura

Leonel Alfredo Gamero Cardenas¹, Paul Adrián Melo Medina¹, Gerby Giovanna Rondán Sanabria, PhD¹

¹Universidad Tecnológica del Perú, Arequipa – Perú, U18303362@utp.edu.pe, U19204560@utp.edu.pe, grondan@utp.edu.pe

Resumen– La inteligencia artificial (IA) en el ámbito del mantenimiento predictivo se está volviendo cada vez más destacada, en especial, para la identificación de problemas en rodamientos de maquinaria industrial. El objetivo de la presente revisión sistemática de la literatura (RSL) es mostrar los métodos basados en IA son los más efectivos para la predicción de fallas en el análisis de diversas averías en rodamientos de maquinarias industriales. En la metodología se realizó una búsqueda manual de artículos originales en Scopus obteniendo 295 en total, de los cuales 55 estudios llegaron a cumplir con los criterios de inclusión establecidos. La aplicación de la inteligencia artificial para la identificación de problemas reduce los costos asociados a fallas de rodamientos, e incrementa en gran parte, la efectividad en la detección de fallas. Finalmente, los métodos con mayor eficiencia incluidos en esta RSL fueron: el método de red neuronal basada en una red de cápsula con bloque inicial (ICN) y el método de entropía de dispersión multiescala compuesta refinada (RCMDE.) con una eficiencia del 100% respectivamente.

Palabras Claves– Inteligencia Artificial – Rodamientos – Fallas – Diagnóstico.

I. INTRODUCCIÓN

Hoy en día, la inteligencia artificial impulsada mediante la digitalización ha experimentado un crecimiento significativo en la toma de decisiones y procesos operativos de las empresas. Este avance se ha centrado en aumentar la eficiencia y la calidad de procedimientos de manufactura [1] [2]. En este contexto, las relaciones que se presentan en esta industria entre las operaciones de producción, los materiales utilizados y los costos desde una perspectiva de ingeniería brinda a las empresas la seguridad de mantener una calidad óptima en sus procesos de producción, siempre manteniendo las condiciones de operación dentro de un rango nominal de valores, bajo una condición de control, evitando desviaciones que pondrían poner en riesgo las operaciones de la empresa [3].

Las empresas enfrentan en la actualidad el problema de gestionar adecuadamente la maquinaria de planta, que se vuelve cada vez más compleja y costosa, y los métodos tradicionales de mantenimiento preventivo ya no son suficientes para garantizar un funcionamiento óptimo [2]. Por lo tanto, se requiere de un enfoque más inteligente y el uso de herramientas, dando lugar al mantenimiento predictivo moderno. El principal desafío en este enfoque es la capacidad de poder diagnosticar los diferentes tipos de falla de rodamientos que existen, como, por ejemplo, la falla de la

pista interna del rodamiento, falla de pista externa y fallas de elementos rotatorios [1] [3].

Por ello, con el avance actual que ha tenido la inteligencia artificial, respaldada y sustentada por un enfoque basado en datos para realizar un exitoso mantenimiento predictivo, se ha convertido en la base para el diagnóstico de fallas en la industria.

En esta RSL, se analizó la aplicación de la inteligencia artificial en la predicción de posibles averías en los rodamientos de maquinaria industrial, identificando las ventajas como la detección temprana de las fallas, y la minimización de costos de mantenimiento inesperados, asimismo, el uso de la inteligencia artificial permitirá tomar decisiones informadas en la gestión de maquinaria y recursos disponibles para mantener las máquinas en óptimas condiciones [4]. Para lograr un enfoque completo de la inteligencia artificial en la detección de fallas en rodamientos, es esencial considerar una base de datos amplia y sólida, que no solo permita enfocarnos en un solo tipo de método, sino en varios [2] [5].

Para un estudio completo es necesario analizar como los distintos métodos de inteligencia artificial predicen y detectan el máximo número de fallas en rodamientos de máquinas industriales con una precisión sumamente eficaz, por ello es necesario realizar un estudio que no sólo muestre como se pueden aplicar distintos enfoques de inteligencia artificial en la anticipación del mantenimiento para equipos, sino también los distintos tipos de métodos [5]. Esto implica tener en cuenta los diferentes tipos de diagnósticos, la generación y compilación de datos; y cómo utilizar esta información para predecir con éxito las fallas en rodamientos de las máquinas industriales [4].

II. METODOLOGÍA

La metodología utilizada, se encuentra enfocada en la revisión sistemática de información confiable a través de la base de datos Scopus, fue empleada la metodología PICO, que descompone la pregunta de búsqueda en cuatro componentes claves que sirven para identificar el problema (P), la intervención (I), la comparación (C) y los resultados (O).

A. Pregunta PICO

En principio, la pregunta de investigación PICO ha sido formulada de la siguiente manera:

RQ: ¿Qué métodos de inteligencia artificial son los más eficientes para la predicción de fallas en rodamientos de máquinas industriales?

RQ1 (Problema): ¿De qué manera se emplea la inteligencia artificial para identificar fallas?

RQ2 (Intervención): ¿Qué métodos de inteligencia artificial se aplicaron para la predicción de fallas en rodamientos de máquinas industriales?

RQ3 (Comparación): ¿Qué métodos de inteligencia artificial no son tan eficientes?

RQ4 (Resultados): ¿Qué métodos resultaron ser los más eficientes para la predicción de fallas en rodamientos de máquinas industriales?

B. Palabras Clave

En la Tabla I, se muestran las palabras clave específicas para cada componente PICO en función de la problemática, intervención, comparación y resultados, las cuales nos servirán como base para la elaboración de la ecuación de búsqueda en Scopus.

TABLA I
PALABRAS CLAVE DE LA ECUACIÓN PICO

Palabras clave de la ecuación PICO			
P	Problema / Población	Inteligencia artificial / Máquinas Industriales	Artificial intelligence, IA, Mathematic models, Machine learning, Industria 4.0, Algorithm, Neural network.
I	Intervención	Predicción de fallas en rodamientos de máquinas industriales	Predictive maintenance, Failures, Prediction, Industrial rotating machines, Machines, Bearings, Fault diagnostic,
C	Comparación	Métodos menos eficientes de detección de fallas en rodamientos de máquinas industriales	Methods, Tools, Tipes, Techniques, Procedures, Approaches, Strategies, Systems.
O	Resultados	Métodos más eficientes para la predicción de fallas en rodamientos	Efficiencys, Effectiveness, Optimization, Performance, Productivity.

C. Sintaxis de la ecuación de búsqueda empleada

En la Tabla II, se estructura la sintaxis de la fórmula, para obtener resultados de manera precisa y relevante para la presente RSL.

TABLA II
PALABRAS CLAVE DE LA ECUACIÓN PICO

Términos de etiqueta empleados	
P	Problema / Población
I	Intervención
C	Comparación

“Artificial intelligence” OR “IA” OR “Mathematic models” OR “Machine learning” OR “Industria 4.0” OR “Algorithm” OR “Neural network”

“Predictive maintenance” OR “Failures” OR “Prediction” OR “Industrial rotating machines” OR “Machines” OR “Bearings” OR “Fault diagnostic”

“Methods” OR “Tools” OR “Tipes” OR “Techniques” OR “Procedures” OR “Approaches” OR “Strategies” OR “Systems”

O	Resultados	“Efficiencys” OR “Effectiveness” OR “Optimization” OR “Performance” OR “Productivity”
----------	------------	---

Teniendo como base las palabras clave para cada componente, se formuló la ecuación de búsqueda. Para ello, fueron empleados operadores booleanos AND y OR. La cual generó una ecuación de búsqueda que englobó términos claves relacionados con la inteligencia artificial, fallas, diagnóstico, maquinaria industrial, rodamientos, enfoques de detección, tal como sigue: “Artificial AND Intelligence AND Failure OR Diagnostic AND Industrial AND Machine OR Bearings AND Data OR Approaches”

D. Criterios de Inclusión y Exclusión

En primer lugar, se han definido criterios para incluir o excluir los estudios relevantes, mostrando que los *ESTUDIOS INCLUIDOS* deben abordar los siguientes aspectos:

CI1: Los estudios deben tener relación con métodos de inteligencia artificial basados en modelos matemáticos y algoritmos, siempre y cuando tengan como ingreso, flujos de datos constantes sobre el estado de los rodamientos de las máquinas industriales.

CI2: Los artículos deben tener información sobre máquinas industriales y aplicación de la inteligencia artificial como parte del estudio, sobre todo en lo que respecta a los rodamientos que forman parte de esta y de las fallas que presentan respectivamente.

CI3: Los estudios deben incluir información de inteligencia artificial sobre el historial de fallas de maquinaria industrial, antes y después de incluir métodos predictivos para la mejora de la detección de problemas en rodamientos.

CI4: Los estudios deben tener información sobre los tipos de falla que presentan los rodamientos de los equipos, además de especificar el método o modelo de inteligencia artificial aplicado para el diagnóstico de la posible falla.

En segundo lugar, *SE EXCLUYEN* artículos que, posean las siguientes características:

CE1: No se considerarán artículos con una antigüedad mayor a 5 años (2018) desde su fecha de publicación.

CE2: Los artículos no deben estar relacionados con los campos de medicina e industria alimentaria.

CE3: Los artículos no deben estar en otro idioma que no sea el inglés y español.

CE4: Estudios que no sustenten la elección del método o modelo de inteligencia artificial con el fin de identificar fallas en los rodamientos de equipos industriales.

E. Esquema de flujo PRISMA

Finalmente, en la Fig. 1, se incluyó el diagrama de flujo PRISMA, que muestra el proceso del análisis de literatura, utilizando Scopus como fuente de información. Inicialmente, se identificaron un total de 295 estudios, de los cuales, se procedió al cribado de estudios. De estos, 178 registros fueron excluidos, puesto que 50 pertenecían al sector electrónico, 29 al sector de la salud y 99 a otros sectores.

En la etapa de cribado, se recuperaron 117 publicaciones para su posterior evaluación, sin embargo, 10 publicaciones no pudieron ser descargadas a texto completo, de las 107 publicaciones restantes para determinar su elegibilidad, 52 fueron excluidas por las siguiente razones: (CE2) los artículos que estaban relacionados con los campos de medicina e industria alimentaria, fueron 20 estudios, seguido por los estudios que no sustentan la elección del método para la detección de fallas de rodamientos de equipos industriales (CE4) fueron 32 estudios.

Finalmente, se incluyeron 55 estudios para la RSL los cuales constituyen la parte fundamental para el análisis y desarrollo de la presente investigación.

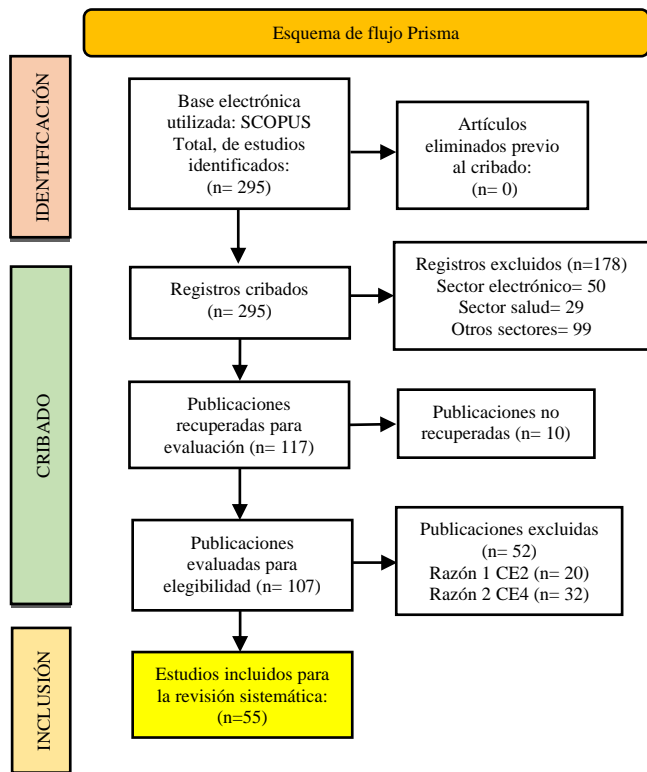


Fig. 1 Análisis de datos por la metodología PRISMA.

III. RESULTADOS

Después de completar la elaboración del flujo PRISMA, se obtuvieron un total de 55 investigaciones que formaron parte de la presente RSL.

A. *RQ1 (Problema): ¿De qué manera se emplea la inteligencia artificial para identificar fallas?*

En la Fig. 2, se observa un crecimiento de los artículos vinculados a la inteligencia artificial para predecir defectos en rodamientos de maquinaria industrial. Es importante destacar que la IA muestra un patrón de expansión durante los 5 últimos años.

También en la Fig. 3, se destacan los países que lideran la investigación en IA, siendo China el país con mayor cantidad

de estudios experimentales. Este país demuestra un crecimiento constante en tecnología e innovación, principalmente en el tema de análisis de fallas e inteligencia artificial.

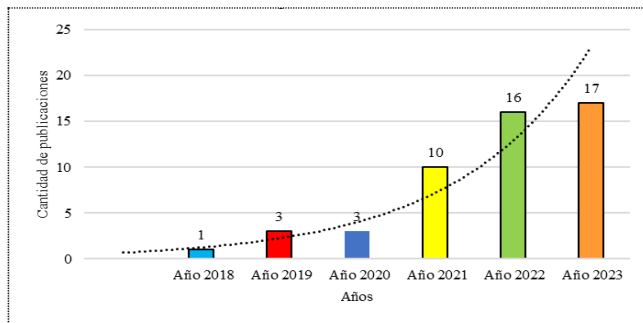


Fig. 2 Publicaciones relacionados a la inteligencia artificial en los últimos 5 años

Asimismo, podemos mencionar que el campo de la inteligencia artificial y automatización para la prevención de fallas. Además, observamos una presencia significativa de investigaciones experimentales en el campo de la inteligencia artificial y la automatización para la prevención de fallas en países emergentes en el mercado mundial, como lo evidencian los estudios realizados en India [17], [21], [37], [47]. En este país, cada vez más empresas incorporan estas tecnologías en sus procesos.

También países del medio oriente, como Bangladesh e Irak, están empezando a tomar en cuenta, automatizar la detección de fallas en sus máquinas industriales aplicando la IA, para así tener una mayor confiabilidad en la producción de sus empresas [40],[45]. Y es que la aplicación de la inteligencia artificial está pasando de ser una herramienta aplicada solo en las grandes potencias como China, a ser utilizada también en países, donde la automatización no es muy común, tal como lo demuestran los artículos de estudios experimentales realizados en Taiwán [22], Vietnam [55] y Malasia [14].

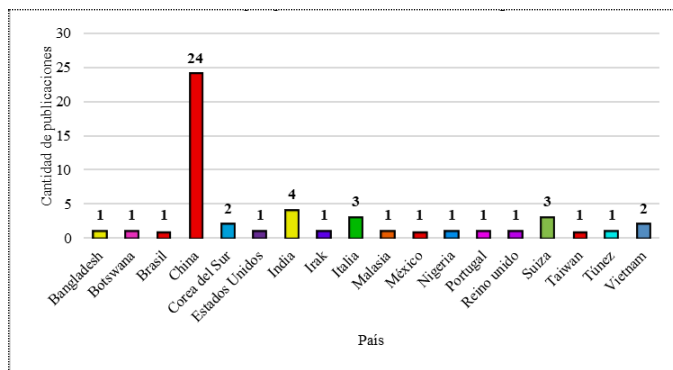


Fig. 3 Publicaciones de artículos de revisión relacionados a la inteligencia artificial

Dado el incremento de la publicación de artículos experimentales en este campo conforme avanzan los años, el

uso de la inteligencia artificial, está pasando a ser aplicada por las grandes potencias del mundo, a ser aplicada por el resto de los países, como parte de sus procesos industriales, lo que demuestra la viabilidad de su uso en la industria

B. RQ2 (Intervención): ¿Qué métodos de inteligencia artificial se aplicaron para la predicción de fallas en rodamientos de máquinas industriales?

Cada estudio experimental incluyó un conjunto de datos que abordó las fallas producidas en los rodamientos, las cuales se clasificaron en las siguientes categorías: Estado normal (N), Falla en la pista exterior (FE), Falla en la pista interior (FI), Falla mixta de pista interior y exterior (FI/E), Falla de la bola (FB) y Falla de los rodillos (FR). Estos detalles se encuentran especificados en la Tabla III. A partir de este análisis, se observa que la (FE) y (FI) son las más recurrentes y han sido el punto de mayor atención y estudio.

Cabe recalcar que no son muchos los autores que decidieron incluir entre sus modelos de falla, aquellos que incluyan la falla mixta de las pistas interior y exterior, ya que son casos poco comunes, pero que aún así dan mayor validez a sus experimentaciones, siendo estos los casos de estudio [12], [13], [26] y [51].

Las fallas en rodillos, se dan sólo en los rodamientos de este tipo, ya que son los de bolas los más utilizados en la industria, los autores que incluyeron la experimentación en este tipo de falla, tal como el caso de los autores [7], que indujeron estas fallas mediante descargas eléctricas en módulos experimentales que contaban con rodamientos de este tipo, mientras que en otros casos experimentales, se aplicaron las redes neuronales, empezando con la programación de los algoritmos basados en flujos de información previos de las maquinarias de la industria del caso, y datos en tiempo real, obtenidos gracias a sensores ubicados en partes estratégicas de los distintos equipos industriales [18], [20], [48], [50].

En cuanto a los estudios experimentales más completos respecto al número de tipos de fallas que analizan, se tendrían los artículos [12], [13],[26] y [51].

TABLA III
VISIÓN GENERAL DE LAS FALLAS EN LOS RODAMIENTOS DENTRO DE LOS ESTUDIOS ANALIZADOS

Falla	Autor(es)
(N)	[6], [7], [10] - [13], [19], [22], [28] - [31], [33], [43], [48], [50] - [54]
(FE)	[7] - [13], [18], [19], [21] - [34], [37] - [39], [41], [43], [44], [46] - [55]
(FI)	[7], [13], [18], [19], [21] - [35], [37] - [39], [41], [43], [44], [46] - [54]
(FI/E)	[12], [13], [26], [51]
(FB)	[7], [13], [22] - [29], [31], [33], [34], [37], [39], [43], [46], [48] - [52], [54]
(FR)	[11], [19], [47]

En la Fig. 4, se observa que la (FE) y (FI) son los tipos de fallas de rodamientos que más se analizan mediante los diversos métodos de inteligencia artificial, con un total de 39 análisis de fallas cada una.

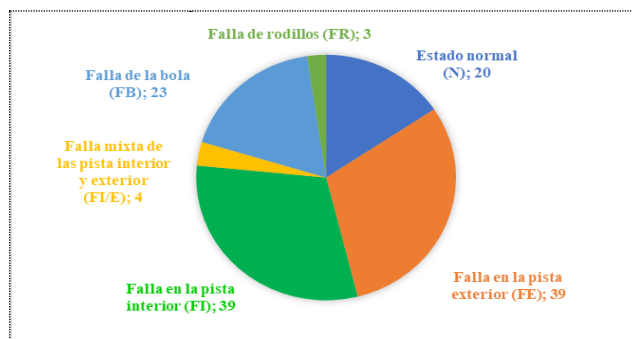


Fig. 4 Fallas analizadas por los distintos métodos de inteligencia artificial

Si bien cada método experimental implicó la recopilación y análisis de fallas en varios tipos de rodamientos, la Tabla IV nos muestra que se examinaron los siguientes rodamientos: de bolas, de bolas/rodillos, y de rodillos.

Debido a esto se destaca que el rodamiento de bolas fue el que más ha estudiado a través de los distintos métodos, principalmente debido a su amplia utilización en diversas aplicaciones industriales y maquinaria; siendo en algunos casos el único tipo de rodamiento estudiado, como el artículo de estudio propuesto por los autores [5], donde este tipo de rodamiento es el más adecuado para su modelo de diagnóstico inteligente basado en Kurtogram-SM.

De la misma forma, los artículos [9] - [11], cuyas redes neuronales parten de modelos básicos que analizan de forma concreta, las fallas en rodamientos de bolas en máquinas industriales.

TABLA IV
TIPOS DE RODAMIENTOS ESTUDIADOS

Tipo de Rodamiento	Autor(es)
Rodamiento de bolas	[6], [7], [9] - [11], [13], [16] - [22], [25], [26], [28] - [30], [33] - [38], [41] - [46], [48] - [52], [54], [55]
Rodamiento de bolas/ de rodillos	[8], [14], [15], [23], [27], [39], [47], [53]
Rodamiento de rodillos	[12], [31], [32]

Después de analizar diversos tipos de rodamientos para la predicción de fallas en maquinaria industrial, la Fig. 5, se evidencia que el rodamiento de bolas obtiene la puntuación más alta con un total de 37 estudios, seguido por el rodamiento de bolas y rodillos con 8, y finalmente el rodamiento de rodillos con 3, respectivamente.

Esta observación subraya la razón por la cual los rodamientos de bolas son los más ampliamente empleados en la industria, dado que desempeñan un papel crítico en la operación eficiente y fiable de la maquinaria industrial.




Fig. 5 Tipos de rodamientos estudiados en los diferentes métodos de inteligencia artificial

C. Q3 (Comparación): ¿Qué métodos de inteligencia artificial no son tan eficientes?

La Tabla V, muestra que el método de la Transformada wavelet continua es el método menos eficiente, con una eficiencia del 83.3 %, donde los autores aplicaron un modelo de aprendizaje automático (ML), aplicando una transformada Wavelet continua (CWT), con un sistema de clasificación en MATLAB [37], la baja eficiencia obtenida se dio debido a que no se emplearon más funciones estadísticas para un mejor pronóstico y por el uso de MATLAB para la clasificación, ya que este programa, posee limitaciones en cuanto a la cantidad de datos de ingreso por segundo que puede manejar para la clasificación de fallas.

Asimismo, el método de diagnóstico de fallas impulsado por gemelos digitales [31], es el segundo método menos eficaz, con una eficiencia del 83.5 %; donde se propone un nuevo modelo, combinando métodos de adaptación de dominio de última generación (DACD), donde el funcionamiento, parte de introducir datos simulados con datos de prueba, para así mejorar la confiabilidad del diagnóstico, a pesar de que muestra mejores resultados que métodos tradicionales como el método de adaptación sin dominio (Non- DA) y el método de adaptación de dominio basado (MMD), su eficiencia no llega a ser tan alta como otros casos de estudio, como el de los autores [7], que llegaron a obtener una confiabilidad del 100% [7], gracias a que utilizaron un modelo de red neuronal basada en una red de cápsula con bloque inicial (ICN), que utiliza distintos modelos neuronales como clasificadores de vectores de soporte (SCV), red de inicio profundo (ACDIN), K-vecino más cercano (KNN), junto con un sistema de regresión, que evita las fallas de clasificación y una mejor compilación de datos.

D. RQ4 (Resultados): ¿Qué métodos resultaron ser los más eficientes para la predicción de fallas en rodamientos de máquinas industriales?

La Tabla V, muestra los índices de eficiencia de los diversos métodos analizados en los estudios, los que han sido agrupados en 3 categorías con intervalos de 5%, siendo estos: Menos eficientes (<89.5%), Eficientes (90% - 95%) y Altamente eficientes (95,5% - 100%), lo que permite

identificar de manera ascendente cuáles fueron los métodos más eficaces para predecir fallas en rodamientos de maquinaria industrial.

Se observa que el método menos eficiente fue el de la transformada de wavelet continua con un 83.3%, mientras que los métodos más eficientes resultaron ser el Método de divergencia Kullback-Leible, el Método de entropía de dispersión multiescala compuesta refinada y la Convolutional red neuronal con bloque inicial, todos con una eficiencia del 99.9% y 100%, respectivamente.

El método más eficiente es el de una red neuronal basada en una red de cápsula con bloque inicial (ICN) [7], que utiliza distintos modelos neuronales conocidos como AlexNet y Resnet, junto a clasificadores de vectores de soporte, K-vecino más cercano, red de inicio profundo.

La eficiencia lograda por este método se basó en dos grandes factores que influyen mucho a la hora de realizar pronósticos de fallas, el primero, el ingreso de datos, que optimizaron al aplicar una gama de redes neuronales, y segundo, una clasificación de fallas más confiable, al aplicar un sistema de regresión en cápsula (ICN), que se ramifica según el tipo de falla, lo que hace más seguro el diagnóstico.

TABLA V
EFICIENCIA DE LOS MÉTODOS ANALIZADOS EN LOS ESTUDIOS

Autor(es)	Métodos fue discutido en el estudio	Eficiencia
[37]	Transformada wavelet continua	83.3%
[31]	Método de diagnóstico de fallas impulsado por gemelos digitales.	83.4%
[16]	Redes neuronales	87.8%
[17]	Mecanismo de atención mediante representaciones de frecuencia temporal (TFR).	89.5%
[12]	Método transformador convolucional eficiente (ECTN)	90.0%
[32]	Modelo SHAP información mutua ajustada (AMI)	90.0%
[18]	Método red neuronal convolucional (CNN) de trasplante de parámetros	94.4%
[11]	Multimodelo profundo convolucional y teoría mejorada (Dempster-Shafer)	94.8%
[15]	Método basado en regresión adaptativa	95.0%
[24]	Machine Learning	95.5%
[22]	Método SVM gaussiano medio	96%
[54]	Modelo de SAI híbrido con DANN	96.0%
[49]	Modelos de pronóstico CNN, LSTM y CNN-LSTM	96.8%
[20]	Red neuronal convolucional ramificada de múltiples escalas	97.0%
[35]	Método de dominio común, red neuronal convolucional unidimensional (1D-CNN)	97.0%
[40]	Modelo Auto DNN, El bosque aleatorio (RF), el clasificador de aumento de gradiente (GBC), los árboles adicionales (ET)	97.0%
[51]	Algoritmo de optimización de gaviota (SOA)	97.1%
[23]	Componentes principales (PCA) y máquinas de vectores de soporte (SVM)	97.4%
[55]	Modelo de adaptación de subdominios multicapa	97.4%
[25]	Media Móvil Integrada (ARIMA)	97.5%
[39]	Metodología automática no invasiva, mediante señales de flujo parásito	97.5%
[53]	Método de diagnóstico de fallas de rodamientos que incorpora un sistema adaptativo mejorado sin	97.5%

	parámetros (IAPEWT)	
[14]	Método de redes neuronales convolucionales (CNN) y mapas de orden	97.6%
[26]	Método Maml-Triple	98.0%
[33]	Algoritmo Easy-SMT	98.0%
[43]	Algoritmo Easy-SMT, Algoritmo LDDI	98.0%
[47]	Método LMD / Método EWT / Método VMD	98.0%
[52]	Método de fusión de información del codificador automático variacional (VAE) y los métodos de bosque aleatorio (RF)	98.1%
[6]	Kurtogramas y modelos de secuencia de aprendizaje profundo.	98.3%
[45]	AlexNet modificado	98.3%
[13]	Método EMD / Método EEMD / Método LMD / Método EWT / Método VMD	98.5%
[28]	Fusión de entropía de información heterogénea multidominio	98.6%
[42]	Método de redes neuronales convolucionales (CNN) y mapas de orden	98.6%
[21]	Enfoque integrado del sistema de inferencia neuro difusor adaptativo	98.7%
[29]	Método de fusión neuronal convolucional de conjunto y una red neuronal profunda.	99.0%
[9]	Redes gráficas neuronales (GNNBFD)	99.1%
[38]	Marco de aprendizaje de pocas tomas fundamentado en meta aprendizaje independiente	99.1%
[44]	Redes neuronales convolucionales (CNN)	99.1%
[41]	Método de redes neuronales convolucionales CNN dilatada unidimensional	99.3%
[34]	Método de fusión de información multisensor y la red neuronal convolucional (CNN)	99.4%
[19]	Aprendizaje automático: SHAP y características locales basadas en la profundidad	99.5%
[27]	Redes neuronales convolucionales profundas con núcleo ancho de primera capa (WDCNN)	99.5%
[50]	Modelo de red de aprendizaje profundo ConvNext mejorado.	99.5%
[8]	Codificador automático profundo (DAE) y una red neuronal convolucional (CNN)	99.6%
[10]	Red neuronal convolucional separable profunda multicanal (MCDS-CNN)	99.8%
[36]	Método KPCA mejorado, Redes CNN y ResNet	99.9%
[46]	Método de redes neuronales convolucionales CNN multiescala mejorada	99.9%
[48]	Método de divergencia Kullback-Leibler (KLD) y variación	100.0%
[30]	Método de entropía de dispersión multiescala compuesta refinada (RCMDE)	100.0%
[7]	Red neuronal convolucional basada en una red de cápsula con un bloque inicial (ICN)	100.0%

Para finalizar y dar respuesta a la pregunta de investigación PICO, sobre la aplicación de métodos eficientes, para predecir fallas en rodamientos de maquinaria industrial. La Fig. 6, muestra la cantidad de métodos y su eficiencia de confiabilidad, de ahí que, 41 métodos alcanzan una alta eficiencia, situándose entre el 95.5% y el 100%, seguidamente, se identifican 5 métodos que demuestran una eficiencia notable, con porcentajes entre el 90% y el 95%.

Por último, se registran 4 métodos con una eficiencia relativamente menor, con un porcentaje inferior al 89.5%.




Fig. 6 Cantidad de métodos eficientes de inteligencia artificial

IV. DISCUSIÓN

La detección de fallas empleando la inteligencia artificial, es cada vez más frecuente, esto de acuerdo a la tendencia que se observa en la Fig. 2, donde se puede ver un crecimiento exponencial de artículos relacionados a su aplicación, sobre todo en los últimos años, donde el 86% de los artículos de investigación pertenecen a los últimos tres años, asimismo otro punto a recalcar es que el 48% de los artículos de estudio relacionados a esta revisión, son del país de China, el cual, es un país a la vanguardia de la tecnología, siempre buscando optimizar los procesos industriales en sus empresas, por lo que la cantidad de artículos relacionados a este tema, provenientes de este país es bastante alta, mientras que el 52% restante, se encuentra repartido entre los demás países, teniendo los porcentajes más altos después de China e India con un 8% del total de artículos y Suiza con un 6%. Por ende, la aplicación de la inteligencia artificial para detectar fallas en rodamientos implica distintas formas de hacerlo, desde la programación de una secuencia de códigos y algoritmos, que permitan al programa aplicado retroalimentarse para la detección de fallas, hasta la utilización de métodos ya conocidos y aplicarlos en simultáneo.

Algo en común de todos los métodos, es que se requiere una base de datos, que es obtenida mediante sensores ubicados en lugares estratégicos de los equipos, también se obtienen de bases de datos basada en el historial de fallas y características del equipo o datos extraídos de simulaciones en programas al ingresar las características del equipo en cuestión.

Con el constante ingreso de datos y con patrones de reconocimiento de las fallas más comunes, estos métodos permiten diagnosticar fallas en rodamientos antes de que ocurran, lo que permite ahorrar en costos de mantenimiento a las empresas que utilizan estos métodos.

Se aplicaron distintos métodos, como el caso del autor [6], el cual ejecuta una serie de kurtogramas y códigos secuenciales de aprendizaje profundo. Sin embargo, el autor [23], aplica métodos ya conocidos en simultáneo de los análisis de componentes principales y máquinas de vectores de soporte, para la identificación de fallas en rodamientos de velocidad variable. En cambio, el autor [40] aplica el método AutoML para la clasificación y prevención de fallas en la industria para el mantenimiento predictivo, de igual manera, se realiza la aplicación de la inteligencia artificial partiendo de

la mezcla de distintos códigos secuenciales, lo que da lugar a nuevos métodos [11], como el método de fusión de decisión multimodelo basado en DCNN-IDST y el de una red neuronal convolucional ramificada de varias escalas optimizada [19].

El método menos eficiente, con una eficiencia del 83.3%, fue el de la transformada Wavelet, la baja eficiencia obtenida fue el resultado de emplear funciones estadísticas a mayor escala, para un mejor pronóstico y por el uso de MATLAB para la clasificación, puesto que este programa, a pesar de su gran capacidad de procesar datos, es limitada para la cantidad de datos que se ingresaron en el estudio [37].

Otro método que demostró no ser tan eficaz es el de los autores [31], que es una red digital de adaptación de dominio parcial basada en gemelos digitales, con una eficiencia del 83.5 %, donde se propone un modelo nuevo que aplica los métodos de adaptación de dominio de última generación, cuyo funcionamiento empieza con el ingreso de datos simulados en conjunto con datos de prueba reales del equipo.

De todos los métodos revisados, 41 métodos presentan una eficiencia superior al 95.5%, lo que indica que la inteligencia artificial, es altamente efectiva. El método más eficiente es el de una red neuronal basada en una red de cápsula con bloque inicial [7], que utiliza distintos modelos neuronales, entre ellos, AlexNet y Resnet, junto a clasificadores de vectores de soporte y la red de inicio profundo, llegando a tener un 99.9% de eficiencia en promedio aplicando diversas combinaciones de métodos, junto con un 100% al establecer la red neuronal completa.

Mientras que el segundo método más eficiente fue el Método de entropía de dispersión multiescala compuesta refinada de los autores [30], con una eficiencia del 100%, el cual se enfoca en la extracción de fallas comunes basadas en los modelos VDM y RCMDE, con una recopilación de datos por el programa WTDS, al aplicar estos en conjunto se obtiene un pronóstico de falla realmente alto, gracias a que los registros, son clasificados y recopilados de manera eficiente por la RCMDE, que analiza las variaciones en las vibraciones, proporcionando de esta manera el pronóstico correcto.

V. CONCLUSIONES

En síntesis, la presente RSL muestra una tendencia alentadora del uso de los distintos métodos de inteligencia artificial para anticipar posibles fallas en rodamientos de máquinas industriales. A lo largo de los estudios revisados, se evidencia un acuerdo sobre la urgencia de mejorar la confiabilidad y eficiencia para la detección de fallas en rodamientos mediante la implementación de métodos eficientes. Los métodos más eficientes para la predicción de fallas en rodamientos fueron el método de entropía de dispersión multiescala compuesta refinada y la red neuronal convolucional basada en una red de cápsula con un bloque inicial, los cuales alcanzaron una eficiencia del 100%. A medida que la industria avanza hacia la Industria 4.0, esta revisión subraya la importancia de la integración de

tecnologías novedosas con el fin de mejorar la eficiencia del mantenimiento predictivo. La combinación de inteligencia artificial se presenta como un enfoque integral para monitorear y prever las fallas en rodamientos de manera proactiva, facilitando una administración efectiva de los recursos y reduciendo tiempos de inactividad no planificados.

Para futuros trabajos, se recomienda realizar una revisión, en la cual los métodos propuestos puedan recopilar datos en un entorno del mundo real, permitiendo verificar de manera más exhaustiva la efectividad de dichos métodos, validando su eficacia y precisión de inferencia en un contexto de producción.

AGRADECIMIENTOS

Los autores expresan su sincero agradecimiento a la Universidad Tecnológica del Perú por la iniciativa de llevar a cabo esta revisión sistemática de la literatura, así como por el valioso asesoramiento brindado durante todas las etapas del desarrollo de la investigación. Esta colaboración ha sido fundamental para enriquecer nuestro trabajo y contribuir al avance del conocimiento en este campo

REFERENCIAS

- [1] D. Cardoso, L. Ferreira, "Application of Predictive Maintenance Concepts Using Artificial Intelligence Tools", *Applied Sciences*, vol 11, no. 18, pp. 1-18, Febrero 2021.
- [2] Manavalan, Ethirajan, and Kandasamy Jayakrishna. "A review of Internet of Things (IoT) embedded sustainable supply chain for industry 4.0 requirements." *Computers & Industrial Engineering* 127 (2019): 925-953.
- [3] S. Gawde, S. Patil, S. Kumar, P. Kamat, K. Kotecha, A. Abraham, "Multi-fault diagnosis of Industrial Rotating Machines using Data-driven approach: A review of two decades of research", *Engineering Applications of Artificial Intelligence*, vol 123, no. 106139, Agosto 2023.
- [4] N. M. M. Sobran, Z. H. Ismail, "A Systematic Literature Review of Unsupervised Fault Detection Approach for Complex Engineering System", *Engineering Applications of Artificial Intelligence*, vol 103, pp. 43-60, Marzo 2023.
- [5] [L. Kenisuomo, A. Yunusa-Kaltungo, S. Yusuf, Integrated Fault Detection Framework for Classifying Rotating Machine Faults Using Frequency Domain Data Fusion and Artificial Neural Networks, *MDPI*, vol 6, no. 59, Octubre 2018.
- [6] S. Udmale, K. Singh y G. Bhirud, "A bearing data analysis based on kurtogram and deep learning sequence models", *Measurement*, Vol.145, pp. 665-667, Octubre 2019.
- [7] Z. Zhiyu, P. Gaoliang, C. Yuanhang y G. Huijung, "A convolutional neural network based on a capsule network with strong generalization for bearing fault diagnosis", *Neurocomputing*, Vol. 323, pp. 62-75, Febrero 2019.
- [8] S. Xiang, J. Zhang, H. Gao, D. Shi and L. Chen, "A deep transfer learning method for bearing fault diagnosis based on domain separation and adversarial learning", *Shock and Vibration*, vol. 2021, 2021
- [9] L. Xiao, X. Yang y X. Yang, "A graph neural network-based bearing fault detection method", *Scientific Reports*, Vol.13, n° 5286, Marzo 2023.
- [10] L. Ling, Q. Wu, K. Huang, Y. Wang y C. Wang, "A Lightweight Bearing Fault Diagnosis Method Based on Multi-Channel Depthwise Separable Convolutional Neural Network", Vol. 11, n° 4110, Diciembre 2022.
- [11] W. Xu, L. Jing, J. Tan y L. Dou, "A multimodel decision fusion method based on DCNN-IDST for fault diagnosis of rolling bearing", *Open Access Journal*, Diciembre 2020

- [12] W. Liu, Z. Zhang, J. Zhang, H. Huang, G. Zhang y M. Peng, "A Novel Fault Diagnosis Method of Rolling Bearings Combining Convolutional Neural Network and Transformer", *Electronics*, Vol.12, n° 1838, Abril 2023.
- [13] Y. Wei, L. Yuqing, X. Minqiang y H. Wenhui, A Review of Early Fault Diagnosis Approaches and Their Applications in Rotating Machinery, *Entropy*, Vol.14, n° 4, Abril 2019.
- [14] A. Nor, S. Pedapati, M. Masdi y V. Leiva, "Abnormality Detection and Failure Prediction Using Explainable Bayesian Deep Learning: Methodology and Case Study with Industrial Data", *Mathematics*, Vol.10, n° 554, Febrero 2022.
- [15] Y. Zhao, M. Toothman, J. Moyne y K. Barton, "An Adaptive Modeling Framework for Bearing Failure Prediction", *Electronics*, Vol.11, n° 3, Febrero 2022.
- [16] I. Rojek, M. Kaczmarek, M. Piechowski y D. Mikolajewski, "An Artificial Intelligence Approach for Improving Maintenance to Supervise Machine Failures and Support Their Repair", *Applied Science*, Vol. 13, n° 4971, Abril 2023.
- [17] H. Bingbing, T. Jiahui, W. Jimei y Q. Jiajuang, "An Attention Efficient Net-Based Strategy for Bearing Fault Diagnosis under Strong Noise", *Sensors in Civil Structural Health Monitoring*, Vol. 22, n° 17, Agosto 2022.
- [18] X. Ding, H. Wang, Z. Cao, X. Liu, Y. Liu y Z. Huang, "An Edge Intelligent Method for Bearing Fault Diagnosis Based on a Parameter Transplantation Convolutional Neural Network", *Electronics*, Vol.12, n° 1816, Abril 2023.
- [19] L. Brito, G. Susto, J. Brito y M. Duarte, "An explainable artificial intelligence approach for unsupervised fault detection and diagnosis in rotating machinery", *Mechanical Systems and Signal Processing*, Vol. 163, Junio 2021.
- [20] Xu M, Shi Y, Deng M, Liu Y, Ding X, Deng A, "An improved multi-scale branching convolutional neural network for rolling bearing fault diagnosis", *PLoS ONE*, Vol. 18, n° 9, Setiembre 2023.
- [21] G. Kumbhar y E. Sudhagar, "An integrated approach of Adaptive Neuro-Fuzzy Inference System and dimension theory for diagnosis of rolling element bearing", *Measurement*, Vol. 166, Diciembre 2020.
- [22] S. Lin, "Application of machine learning to a medium gaussian support vector machine in the diagnosis of motor bearing faults", *Electronics*, Vol. 18, n° 2266, Setiembre 2021.
- [23] M. Pule, O. Matsebe, R. Samikannu y K. Feng, 2022. "Application of PCA and SVM in Fault Detection and Diagnosis of Bearings with Varying Speed," *Mathematical Problems in Engineering*, Hindawi, vol. 2022, pages 1-12, April.
- [24] D. Cardoso y L. Ferreira, "Application of Predictive Maintenance Concepts Using Artificial Intelligence Tools", *Applied Sciences*, Vol. 11, n°1, Diciembre 2020.
- [25] H. O. Omeregebe, E. Bright y M. Olanipekun, "Bearing failure diagnosis and prognostics modeling in plants for industrial purpose", *Journal of Engineering and Applied Science*, Vol. 70, n° 17, Marzo 2023.
- [26] Q. Sheng, Z. He, T. Zhang, Y. Li, Z. Liu y Z. Zhang, "Bearing Fault Diagnosis Based on Small Sample Learning of Maml-Triplet", *Applied Sciences*, Vol.12, n° 10723, Octubre 2022.
- [27] L. Shi, S. Su, W. Wang, S. Gao y C. Chu, "Bearing Fault Diagnosis Method Based on Deep Learning and Health State Division", *Applied Science*, Vol.13, n° 7424, Junio 2023.
- [28] R. Song, X. Bai, R. Zhang, Y. Jia, L. Pan y Z. Dong "Bearing Fault Diagnosis Method Based on Multidomain Heterogeneous Information Entropy Fusion and Model Self-Optimisation", *Shock and Vibration*, Vol. 2022, n° 7214822, Febrero 2022
- [29] H. Li, J. Huang y S. Ji, "Bearing Fault Diagnosis with a Feature Fusion Method Based on an Ensemble Convolutional Neural Network and Deep Neural Network", *Sensors*, Vol.19, n° 2034, Abril 2019.
- [30] L. Jie, S. Wenlei, W. Hongwei y Z. Fang, "Coordinated approach fusing rcmdc and sparrow search algorithm-based svm for fault diagnosis of rolling bearings", *Sensors*, Vol.21, n° 16, Agosto 2021.
- [31] Y. Zhang, J.C. Ji, Q. Ni, G. Fengshou, K. Feng, Y. Kun, G. Jian, L. Zihao, L. Zheng, "Digital twin-driven partial domain adaptation network for intelligent fault diagnosis of rolling bearing", *Reliability Engineering & System Safety*, Vol. 234, Junio 2023
- [32] K. Jang, K. Salgado, N. Lee y J. Na, "Explainable Artificial Intelligence for Fault Diagnosis of Industrial Processes", *IEEE Free Access*, pp.1-8, Febrero 2023.
- [33] S. Rajabi, A. Mehdi, S. Santini y F. Flamini, "Fault diagnosis in industrial rotating equipment based on permutation entropy, signal processing and multi-output neuro-fuzzy classifier", *Expert System with applications*, Vol.206, Noviembre 2022.
- [34] J. Wang, D. Wang, S. Wang, W. Li y K. Song, "Fault Diagnosis of Bearings Based on Multi-Sensor Information Fusion and 2D Convolutional Neural Network", *IEEE Access*, Vol.9, Febrero 2021.
- [35] T. Kim y J. Chai, "Fault Diagnosis of Bearings With the Common-Domain Data," en *IEEE Access*, vol. 10, pp. 45457-45470, Abril 2022.
- [36] [31] M. Zhou, X. Xu y N. Zhang, "Fault diagnosis of rolling bearings with noise signal based on modified kernel principal component analysis and DC-ResNe", *Intelligence Technology*, Vol. 8, pp. 1014-1028, Febrero 2023.
- [37] H. S. Kumar, U. Gururaj, "Fault diagnosis of rolling element bearing using continuous wavelet transform and K- nearest neighbour", *Material Today: Proceedings*, Vol. 5, Abril 2023.
- [38] E. Sudhagar G. y Kumbhar, "Few-Shot Bearing Fault Diagnosis Based on Model-Agnostic Meta-Learning", *Measurement*, Vol. 166, Diciembre 2020.
- [39] I. Z. Ramirez, A. Osornio, J.A. Daviu, J. Cureño y J. Saucedo, "Gradual wear diagnosis of outer-race rolling bearing faults through artificial intelligence methods and stray flux signals", *Electronics*, Vol.10, n°1486, Junio 2021.
- [40] R. Hadi, H. Hady, A. Hasan, A. Jodah y A. Humaidi, "Improved Fault Classification for Predictive Maintenance in Industrial IoT Based on AutoML: A Case Study of Ball-Bearing Faults", *Processes*, Vol. 11, n° 1507, Mayo 2023.
- [41] K. Dong y A. Lotfipoor, "Intelligent Bearing Fault Diagnosis Based on Feature Fusion of One-Dimensional Dilated CNN and Multi-Domain Signal Processing", *Sensors*, Vol. 23, n° 5607, Junio 2023.
- [42] S. M. Tayyab, S. Charterton y P. Pennacchi, "Intelligent Defect Diagnosis of Rolling Element Bearings under Variable Operating Conditions Using Convolutional Neural Network and Order Maps", *Sensors 2022*, Vol. 22, n° 2023, Marzo 2022.
- [43] H. Li, G. Hu, J. Li y M. Zhou, "Intelligent Fault Diagnosis for Large-Scale Rotating Machines Using Binarized Deep Neural Networks and Random Forests", *IEEE Free Access*, Vol.19, pp. 1109-1119, Febrero 2021.
- [44] L. G. Di Maggio, "Intelligent Fault Diagnosis of Industrial Bearings Using Transfer Learning and CNNs Pre-Trained for Audio Classification", *Artificial Intelligence Enhanced Health Monitoring and Diagnostics*, Vol. 24, Diciembre 2022.
- [45] M. Mohiuddin, M.Saiful, S. Islam, M. Sipom y M. Niu, "Intelligent Fault Diagnosis of Rolling Element Bearings Based on Modified AlexNet †", *Sensors*, Vol 23, n° 7764, Setiembre 2023.
- [46] Y. Jin, C. Chen y S. Zhao, "Multisource Data Fusion Diagnosis Method of Rolling Bearings Based on Improved Multiscale CNN", *Journal of Sensors*, Vol. 2021, n° 2251530, Noviembre 2021
- [47] A. Nor, S. Pedapati, M. Muhammad y V. Leiva, "Overview of Explainable Artificial Intelligence for Prognostic and Health Management of Industrial Assets Based on Preferred Reporting Items for Systematic Reviews and Meta-Analyses", *Sensors*, Vol.21, n° 8020, Noviembre 2021.
- [48] Z. Mezni, C. Delpha, D. Diallo y A. Braham, "Performance of Bearing Ball Defect Classification Based on the Fusion of Selected Statistical Features", *Entropy*, Vol.24, n° 1251, Setiembre 2022.
- [49] A. Wahid, J. Breslin y M. Intizar, "Prediction of Machine Failure in Industry 4.0: A Hybrid CNN-LSTM Framework", *Applied Science*, Vol. 12, n° 4221, Abril 2022.
- [50] C. Zhang, F. Qin, W. Zhao, J. Li y T. Liu, "Research on Rolling Bearing Fault Diagnosis Based on Digital Twin Data and Improved ConvNex", *Sensors*, Vol. 23, n° 5334, Junio 2023.
- [51] J. Xue, X. Liu, H. Xu y D. Zhang, "Research on the seagull optimization algorithm-based convolutional neural network rolling bearing fault diagnosis method", *Engineering Research Express*, Vol.5, n° 3, Agosto 2023.

- [52] J. Ma, C. Li y G. Zhang, "Rolling Bearing Fault Diagnosis Based on Deep Learning and Autoencoder Information Fusion", *Symmetry*, Vol.14,n° 13, Diciembre 2021.
- [53] J. Li, H. Wang, X. Wang y Y. Zhang, "Rolling bearing fault diagnosis based on improved adaptive parameterless empirical wavelet transform and sparse denoising", *Measurement*, Vol. 152, n° 107392, Febrero 2020.
- [54] X. Zong, R. Yang, H. Wang, M. Du, P. You, S. Wang y H. Su, "Semi-Supervised Transfer Learning Method for Bearing Fault Diagnosis with Imbalanced Data", *Machines* 2022, Vol. 10, n° 515, Junio 2022.
- [55] N. D. Thuan, T. H. Nguyen, S. H. Hoang, " Unsupervised Bearing Fault Diagnosis via a Multi-Layer ", *International Journal of Advanced Computer Science and Applications (IJACSA)*, Vol. 14, n° 5, Febrero 2023.