

# Predicción de vida útil remanente en rodamiento aplicando Machine Learning: Una revisión Sistemática de Literatura

*Prediction of remaining useful life in bearings applying Machine Learning: A Systematic Literature Review*

- <sup>1</sup> Sergio Raúl Villacrés Parra  <https://orcid.org/0000-0002-9497-9795>  
Escuela Superior Politécnica de Chimborazo (ESPOCH)

[sergio.villacres@epoch.edu.ec](mailto:sergio.villacres@epoch.edu.ec)

- <sup>2</sup> Mayte Anabel Zavala León  <https://orcid.org/0009-0000-9750-7438>  
Escuela Superior Politécnica de Chimborazo (ESPOCH)

[mayte.zavala@epoch.edu.ec](mailto:mayte.zavala@epoch.edu.ec)

- <sup>3</sup> Mayra Alexandra Viscaíno Cuzco  <https://orcid.org/0000-0003-4987-7797>  
Universidad Técnica de Ambato

[ma.viscaino@uta.edu.ec](mailto:ma.viscaino@uta.edu.ec)



---

## Artículo de Investigación Científica y Tecnológica

Enviado: 10/05/2024

Revisado: 07/06/2024

Aceptado: 08/07/2024

Publicado: 16/08/2024

DOI: <https://doi.org/10.33262/concienciadigital.v7i3.1.3120>

---

### Cítese:

Villacrés Parra, S. R., Zavala León, M. A., & Viscaíno Cuzco, M. A. (2024). Predicción de vida útil remanente en rodamiento aplicando Machine Learning: Una revisión Sistemática de Literatura. *ConcienciaDigital*, 7(3.1), 46-67.  
<https://doi.org/10.33262/concienciadigital.v7i3.1.3120>

---

**CONCIENCIA DIGITAL**, es una revista multidisciplinaria, **trimestral**, que se publicará en soporte electrónico tiene como **misión** contribuir a la formación de profesionales competentes con visión humanística y crítica que sean capaces de exponer sus resultados investigativos y científicos en la misma medida que se promueva mediante su intervención cambios positivos en la sociedad. <https://concienciadigital.org>

La revista es editada por la Editorial Ciencia Digital (Editorial de prestigio registrada en la Cámara Ecuatoriana de Libro con No de Afiliación 663) [www.celibro.org.ec](http://celibro.org.ec)



Esta revista está protegida bajo una licencia Creative Commons AttributionNonCommercialNoDerivatives 4.0 International. Copia de la licencia: <http://creativecommons.org/licenses/by-nc-nd/4.0/>

---

**Palabras claves:**

pronóstico, vida útil remanente, rodamiento, machine learning, deep Learning, extracción de características

**Resumen**

Los equipos de rotación son equipos que con mucha frecuencia se encuentran instalados en toda planta industrial y los rodamientos son los componentes que con mayor frecuencia fallan. Este motiva a que anticiparse a la ocurrencia del fallo en estos elementos, conlleve benéficamente a la reducción de pérdidas ocasionado por estas averías. En tal virtud, realizar un estudio de revisión sistemática de literatura (LSR), que permita conocer cuáles son los principales problemas que abordan las investigaciones en el campo de predicción de la vida útil remanente en rodamientos, así como identificar cuáles son los modelos de Machine Learning más empleados, resulta relevante. Para el desarrollo de este estudio se aplicó la metodología PRISMA, y el protocolo de Kitchenham para garantizar la confiabilidad de los resultados. Como resultado de la etapa selección de información se identificaron 35 artículos publicados en el periodo de 2018 a 2021, los cuales fueron sometidos a análisis. Se identificaron tres problemas que abordan los diferentes estudios: la extracción de características, la identificación de la etapa de degradación y la implementación de modelos generalizables. Los modelos más empleados corresponden al campo de Deep Learning.

**Keywords:**

forecast, remaining useful life, bearing, machine learning, deep learning, feature extraction

**Abstract**

Rotating equipment is equipment that is frequently installed in every industrial plant and bearings are the components that most frequently fail. This motivates anticipating the occurrence of failure in these elements, beneficially leading to the reduction of losses caused by these breakdowns. Therefore, carry out a systematic literature review (LSR) study, which allows us to know what are the main problems that research addresses in the field of prediction of the remaining useful life in bearings, as well as to identify which are the Machine models. Learning more employees, it is relevant. To develop this study, the PRISMA methodology and the Kitchenham protocol were applied to guarantee the reliability of the results. As a result of the information selection stage, 35 articles published in the period from 2018 to 2021 were identified, which were subjected to analysis. Three problems were identified that the different studies address: feature extraction, identification of the

---

degradation stage, and implementation of generalizable models. The most used models correspond to the field of Deep Learning.

---

## 1. Introducción:

Los equipos de rotación son equipos que con mucha frecuencia se encuentran instalados en toda planta industrial; los rodamientos son considerados como componentes críticos porque reducen la fricción entre partes móviles y estacionarias de maquinaria rotativa (J. Wang et al., 2019); y precisamente son los elementos que con mayor frecuencia fallan (Cakir et al., 2021), entre el 50-60% de los fallos en máquinas rotativas de inducción son ocasionados por fallos en rodamientos (Mushtaq et al., 2021); estos fallos pueden generar varias repercusiones para la industria especialmente en el ámbito económico, por lo tanto la detección de anomalías en estos elementos es un aspecto crucial tanto para la seguridad como para la eficiencia de las industrias de procesos modernos (Quatrini et al., 2020). Los intentos por encarar este problema; datan desde la segunda guerra mundial mediante la aplicación de políticas de mantenimiento, que en algunos casos ha resultado ineficaz (Biggio & Kastanis, 2020). Existen dos métodos para la predicción de vida útil en rodamientos, con dos enfoque bien diferenciados: el uno basado en modelos y el otro basado en datos (Ren et al., 2018), que se centra en analizar los datos que caracterizan el estado operativo del rodamiento y encontrar una relación entre éstos y la expectativa de vida útil remanente.

En los últimos años la cuarta revolución industrial, ha introducido conceptos como el mantenimiento predictivo, el cual a través de la medición de vibraciones que aprovecha tanto, los avances en ingeniería de sensores y el análisis de datos ha permitido calcular cuánto tiempo de vida útil remanente (Remaining Useful Life – RUL) tiene un equipo antes de su fallo (Dalzochio et al., 2020); el RUL es un indicador que permite optimizar un plan de mantenimiento, de manera que se eviten pérdidas en la producción por fallos ocurridos de forma imprevista. La cantidad de información que se obtiene en la medición de vibraciones de rodamientos en motores eléctricos, combinado con el empleo de algoritmos de Machine Learning (ML); han demostrado generar buenos resultados en cuanto a: predicción de vida útil remanente (Remaining Useful Life – RUL) en rodamientos.

Los métodos de aprendizaje automático (ML) han surgido como una herramienta prometedora en las aplicaciones de mantenimiento predictivo para evitar fallos en los equipos. Varios algoritmos de ML, se han aplicado con propósitos como, detección, diagnóstico y pronóstico de fallos en rodamientos; sin embargo, a pesar de su versatilidad,

adolecen de un problema y es que su rendimiento depende de la calidad de la información, específicamente de las características que ingresan algoritmo (Çinar et al., 2020).

Las características de señales de vibración, es decir de datos sin procesar de series de tiempo, se categorizan de la siguiente manera: dominio del tiempo, dominio de frecuencia y dominio del tiempo-frecuencia (Biggio & Kastanis, 2020). La extracción de características de una señal de vibración puede realizarse de manera manual en donde las características son de tipo estadístico; o automática empleando un algoritmo de Deep Learning (DL), en tal caso se requiere tener una cantidad de datos lo suficientemente grande, para entrenar tanto al algoritmo y extraer las características como para realizar la predicción de RUL. Varios estudios (Xiaochuan Li et al., 2019; Y. Liu et al., 2016; Z. Liu et al., 2016; Mao et al., 2018) realizados sobre este tema usan un dataset público obtenido de la plataforma PRONOSTIA, la cual ha hecho pruebas de vida acelerado de rodamientos en un laboratorio, con información suficiente para aplicar algoritmos de Deep Learning (Nectoux et al., 2012). En la industria local, si bien existen empresas que han implementado prácticas de medición de vibraciones; sin embargo, la cantidad de información es reducida como para emplear algoritmos de DL.

Este trabajo tiene como propósito identificar cuáles son los principales problemas que abordan los diferentes estudios realizados en este campo y cuáles son los modelos de Machine Learning más empleados.

## 2. Metodología

### Protocolo de revisión

La revisión sistemática de la literatura (SLR) que se presenta en este trabajo se desarrolló en tres etapas: planificación, realización y la elaboración del informe de la revisión. Inicialmente, en la etapa de planificación, fueron definidas las preguntas de investigación que rigen este estudio, se eligieron las palabras clave que caracterizan al tema de estudio y las bases de datos para la búsqueda de información.

### Preguntas de investigación

La especificación de las preguntas de investigación que se pretende responder a través de la SLR, es el aspecto más importante (Kitchenham & Charters, 2007), ya que dirigirán al estudio. En este sentido, se han definido las siguientes preguntas de investigación:

**PI1:** ¿Cuáles son los problemas de predicción de vida útil remanente en rodamientos que han sido resueltos con Machine Learning?

**PI2:** ¿Qué conjuntos de datos se han empleado para entrenar, validar y probar los modelos de predicción de vida útil remanente en rodamientos?

**PI3:** ¿Cuáles son los métodos usados para análisis de la señal de vibraciones tomadas en rodamientos?

**PI4:** ¿Qué métodos de extracción de características de una señal de vibraciones se han empleado para la predicción de vida útil remanente en rodamientos y cuáles son las técnicas o extractores aplicados?

**PI5:** ¿Qué modelos de predicción se han empleado para el cálculo de la vida útil remanente en rodamientos? CLASIFICAR MODELOS DE ML Y MODELOS DE DL

**PI6:** ¿Qué métricas se han empleado para evaluar y cuál es el valor del desempeño de los modelos que predicen la vida útil remanente en rodamientos?

**PI7:** ¿Cuántos estudios presentan como parte de la evaluación del desempeño del modelo, el valor de la desviación estándar?

**PI8:** ¿Cuánto tiempo tardan en hacer la predicción de RUL?

### Enfoque de búsqueda

El objetivo de la investigación fue la directriz del enfoque de esta etapa, para lo cual se implementó un protocolo de búsqueda de literatura orientada a través de la definición de: palabras clave, bases de datos para ejecutar las búsquedas y criterios de selección. La estrategia adoptada para la selección de palabras clave, se fundamentó en la revisión previa de artículos científicos y artículos de revisión publicados en idioma inglés sobre el tema de interés, identificándose las siguientes palabras clave: “rolling bearing”, “remaining useful life”, “useful life prediction”, “machine learning”, “RUL”, “prognosis fault”, “deep learning”, “feature extraction”, “prognostic and health management”.

Las bases de datos consideradas como fuente de consulta fueron: Web of Science (WoS), ScienceDirect, IEEE Xplore, ACM digital library, MDPI, Taylor & Francis, Springer Link. En todos los casos se empleó la opción de búsqueda avanzada que presenta cada fuente. De la combinación de las palabras clave se generaron siete cadenas de búsqueda que se muestran en la Tabla 1. y Tabla 2.

**Tabla 1**

*Cadenas de búsqueda aplicadas a WoS, ScienceDirect, IEEE Xplore.*

No.	Cadenas de búsqueda
1	Title, abstract, keywords: (rolling bearing) AND (remaining useful life OR RUL OR useful life prediction) AND (machine learning)
2	Title, abstract, keywords: (rolling bearing) AND (prognosis fault) AND (machine learning)
3	Title, abstract, keywords: (rolling bearing) AND (remaining useful life OR RUL) AND (deep learning)
4	Title, abstract, keywords: (rolling bearing) AND (prognosis fault) AND (deep learning)

### Tabla 1

*Cadenas de búsqueda aplicadas a WoS, ScienceDirect, IEEE Xplore (continuación)*

No.	Cadenas de búsqueda
5	Title, abstract, keywords: (rolling bearing) AND (remaining useful life OR RUL) AND (feature extraction)
6	Title, abstract, keywords: (rolling bearing) AND (prognosis fault) AND (feature extraction) (All fields)
7	Title, abstract, keywords: (rolling bearing) AND (PHM OR prognostic and health management)

Las cadenas de búsqueda indicadas en la Tabla 1. se aplicaron a las fuentes: Web of Science, ScienceDirect y IEEE Xplore; que fueron bases de datos que permitieron realizar búsquedas en el título, resumen y palabras clave con la cadena de búsqueda descrita; mientras que para las bases de datos: ACM digital library, MDPI y Taylor & Francis, se realizó la búsqueda con la palabra “rolling bearing” en el título y que las demás palabras de la cadena se busquen en todos los campos, aplicando la opción “AllField”, esto debido a que en las bases de datos indicadas se debe especificar para cada palabra en dónde buscar (ver Tabla 2).

### Tabla 2

*Cadenas de búsqueda aplicadas ACM, MDPI y Taylor & Francis*

No.	Cadenas de búsqueda
1	{Title:(rolling bearing) AND Title:(remaining useful life) OR Title:(RUL) OR Title: (useful life prediction)}
2	{Title:((rolling bearing)) AND AllField:(prognosis fault) AND AllField:(machine learning) }
3	{Title:((rolling bearing)) OR AllField:((remaining useful life OR RUL)) AND AllField:((deep learning)) }
4	{Title:((rolling bearing)) AND AllField:((prognostic fault)) AND AllField:((deep learning)) }
5	{Title:((rolling bearing)) AND AllField:((RUL)) AND AllField:(feature extraction) }
6	{Title:((rolling bearing)) AND AllField:((prognostic fault)) AND AllField:((feature extraction)) }
7	{Title:((rolling bearing)) AND Abstract:(( prognostic and health management)) OR Keywords: (PHM) }

Finalmente, para la base de datos Springer Link, se aplicaron las siete cadenas de búsqueda indicadas en la Tabla 2, cada palabra unida por el operador “AND” y que la búsqueda se realice en el título, dado que es lo que permite la opción de búsqueda avanzada de esa base de datos.

### Criterios de selección

Para la delimitación de la SLR, se establecieron criterios de selección, que permiten incluir y excluir la información localizada en la etapa de búsqueda; todos los estudios localizados fueron valorados con los criterios de selección, criterios inclusión (CI), criterios de exclusión (CE). Para que un estudio sea seleccionado y proceda a la etapa de

www.concienciadigital.org

extracción de información, “todos los criterios de inclusión deben ser verdaderos y los criterios de exclusión deben ser falsos” (Kitchenham & Charters, 2007).

**Tabla 3**


*Criterios para selección de estudios.*

Orden de aplicación	Criterios de inclusión (CI) / Criterios de exclusión (CE)
1	<b>CI1:</b> Artículos publicados entre 2018-2021
2	<b>CE1:</b> Artículos de revisión, encuesta y conferencias
3	<b>CI2:</b> Artículos con al menos 5 citas
4	<b>CE2:</b> Artículos duplicados o identificados en otras bases de datos
5	<b>CE3:</b> El título del artículo no está relacionado con el tema de interés
6	<b>CE4:</b> El resumen no proporciona información relevante para el objeto de este estudio

Luego de la aplicación de los criterios de inclusión y exclusión, finalmente se seleccionaron 35 artículos que fueron empleados para extraer información que aportan a responder las preguntas de investigación. En la Figura 1., se indica el procedimiento de búsqueda y selección de estudios para este SLR y los resultados obtenidos en el proceso.


**Figura 1**

*Proceso de filtrado y selección de artículos*




**Figura 2**

*Número de artículos seleccionados en cada base de datos.*



**Figura 3**

*Número de artículos seleccionados por año de publicación*



En la Tabla 4, se indican los estudios que resultaron seleccionados, 35 estudios resultaron producto de la aplicación de los criterios de inclusión y exclusión.

**Tabla 4**

*Estudios seleccionados, que pasarán a la etapa de extracción de información.*

No.	Fuente	Título del artículo	Referencia
1		A Hybrid Prognostics Approach for Estimating Remaining Useful Life of Rolling Element Bearings	(B. Wang et al., 2020)
2		A Deep Learning Method for Bearing Fault Diagnosis Based on Time-frequency Image	(Xiang Li et al., 2019b)
3		Prediction of Bearing Remaining Useful Life With Deep Convolution Neural Network Predicting Remaining Useful Life of Rolling Bearings Based on Deep Feature	(Ren et al., 2018)
4		Representation and Transfer Learning	(Mao et al., 2020)
5	IEEE Xplore	Simultaneous Bearing Fault Recognition and Remaining Useful Life Prediction Using Joint-Loss Convolutional Neural Network	(R. Liu et al., 2020)
6		Feature Extraction for Data-Driven Remaining Useful Life Prediction of Rolling Bearings	(H. Zhao et al., 2021)
7		A Deep Learning-Based Remaining Useful Life Prediction Approach for Bearings Roller Bearing Degradation Assessment Based on a Deep MLP Convolution Neural Network Considering Outlier Regions	(C. Cheng, Ma, et al., 2020)
8		Bearing Performance Degradation Assessment Based on Ensemble Empirical Mode Decomposition and Affinity Propagation Clustering	(D. Zhang et al., 2020)
9		Remaining Useful Life Prediction of Rolling Element Bearings Using Supervised Machine Learning	(Xu et al., 2019)
10		Sparse Optimistic Based on Lasso-LSQR and Minimum Entropy De-Convolution with FARIMA for the Remaining Useful Life Prediction of Machinery	(Xiaochuan Li et al., 2019)
11	MDPI	GMPSO-VMD Algorithm and Its Application to Rolling Bearing Fault Feature Extraction A Double-Channel Hybrid Deep Neural Network Based on CNN and BiLSTM for Remaining Useful Life Prediction	(B. Wu et al., 2018)
12			(Ding et al., 2020)
13			(C. Zhao et al., 2020)

**Tabla 4**

*Estudios seleccionados, que pasarán a la etapa de extracción de información  
 (continuación)*

No.	Fuente	Título del artículo	Referencia
14		A Reliable Prognosis Approach for Degradation Evaluation of Rolling Bearing Using MCLSTM	(Huang et al., 2020)
15	MDPI	An Autoencoder Gated Recurrent Unit for Remaining Useful Life Prediction	(Y.-W. Lu et al., 2020)
16		An Ensemble Learning and RUL Prediction Method Based on Bearings Degradation Indicator Construction	(Tian & Wang, 2020)
17		Bearing Remaining Useful Life Prediction Based on Naive Bayes and Weibull Distributions	(N. Zhang et al., 2018)
18		Bearing remaining useful life estimation using an adaptive data-driven model based on health state change point identification and K-means clustering	(Singh et al., 2020)
19		An integrated approach to bearing prognostics based on EEMD-multi feature extraction, Gaussian mixture models and Jensen-Renyi divergence	(Rai & Upadhyay, 2018)
20		Sparse auto-encoder with regularization method for health indicator construction and remaining useful life prediction of rolling bearing	(She et al., 2020)
21	WoS	Remaining useful life prediction of rolling bearing using fractal theory	(Meng et al., 2020)
22		A novel health indicator based on the Lyapunov exponent, a probabilistic self -organizing map, and the Gini-Simpson index for calculating the RUL of bearings	(Rai & Kim, 2020)
23		Predicting remaining useful life of rolling bearings based on deep feature representation and long short-term memory neural network	(Mao et al., 2018)
24		Remaining useful life prediction of rolling element bearings using degradation feature based on amplitude decrease at specific frequencies	(An et al., 2018)
25		Estimation of Remaining Useful Life of Rolling Element Bearings Using Wavelet Packet Decomposition and Artificial Neural Network	(Rohani Bastami et al., 2019)
26	Springer	Remaining Life Prediction Method for Rolling Bearing Based on the Long Short-Term Memory Network	(F. Wang et al., 2019)
27		Physics-based intelligent prognosis for rolling bearing with fault feature extraction	(Y. Lu et al., 2018)
28		A method for constructing rolling bearing lifetime health indicator based on multi-scale convolutional neural networks	(C. Wu et al., 2019)
29		Deep learning-based remaining useful life estimation of bearings using multi-scale feature extraction	(Xiang Li et al., 2019a)
30		A novel deep learning method based on attention mechanism for bearing remaining useful life prediction	(Chen et al., 2020)
31	Science Direct	A two-stage method based on extreme learning machine for predicting the remaining useful life of rolling-element bearings	(Pan et al., 2020)
32		Bearing remaining useful life prediction using support vector machine and hybrid degradation tracking model	(Yan et al., 2020)
33		A convolutional neural network based degradation indicator construction and health prognosis using bidirectional long short-term memory network for rolling bearings	(Y. Cheng et al., 2021)
34		A Koopman operator approach for machinery health monitoring and prediction with noisy and low-dimensional industrial time series	(C. Cheng, Ding, et al., 2020)
35	Taylor y Francis	Performance degradation assessment of rolling bearing based on convolutional neural network and deep long-short term memory network	(Z. Wang et al., 2020)

### 3. Resultados


#### *Problemas detectados en la predicción de vida útil remanente en rodamientos usando Machine Learning*

Del análisis de la documentación seleccionados, se han identificado que los estudios resuelven los siguientes problemas:

- a) **PROBLEMA1:** Extracción de características: A partir de la señal de vibración, el desafío es extraer características razonables y eficientes para la predicción de RUL y garantizar que la pérdida de información no sea significante para este propósito.
- b) **PROBLEMA 2:** Identificación del inicio de estado de degradación, a través del empleo de Indicadores de salud (Health Incator-HI) y de umbrales. El espectro puede ser dividido en dos fases: la primera parte corresponde a una etapa de operación normal del rodamiento y luego de ésta empieza un proceso de degradación, al final del cual culmina su vida útil.
- c) **PROBLEMA 3:** Modelos no generalizables, debido a que el conocimiento del comportamiento de degradación no puede generalizarse y la fluctuación de la medición causada por el comportamiento de degradación no lineal puede afectar la estabilidad de los resultados de la predicción.

**Figura 4**

*Problemas investigados por los estudios seleccionados.*




*Conjuntos de datos se han empleado para entrenar, validar y probar los modelos de predicción de vida útil remanente en rodamientos.*

Se identificó que el 80% de los estudios analizados emplearon el dataset PRONOSTIA Platform (Ver figura 5). Entre las ventajas que presenta este hecho es que los estudios que emplearon este dataset, es que los resultados obtenidos son comparables, así las metodologías pueden evaluar sus desempeños comparando con los estudios que han empleado el mismo dataset.


**Figura 5**

*Dataset más empleados*



**Figura 6**

*Plataforma de recogida de datos PRONOSTIA (Mao et al., 2018).*



El conjunto de datos utilizado en este experimento proviene del IEEE PHM Challenge 2012 abierto. Este conjunto de datos se recopila de la plataforma de prueba denominada PRONOSTIA, que puede proporcionar toda la señal de vibración de funcionamiento hasta la falla mediante la realización de un experimento de degradación acelerada, como se muestra en la Figura 6.

PRONOSTIA consta de tres partes: una parte giratoria, una parte de generación de degradación y una parte de medición. La potencia del motor de la parte giratoria equivale

a 250 W, que transmite el movimiento giratorio al rodamiento de prueba. La parte de carga proporciona fuerza radial al rodamiento de prueba para reducir la vida útil del rodamiento. Y, la parte de medición está compuesta por dos acelerómetros que se colocan en cada rodamiento para captar las señales de vibración horizontal y vertical. Este desafío de pronóstico proporciona tres grupos de datos en diferentes condiciones de funcionamiento (Mao et al., 2018).

*¿Cuáles son los métodos usados para análisis de la señal de vibraciones tomadas en rodamientos?*


De la revisión de la literatura se ha identificado que una vez que se toma la medida de vibración, esta puede ser analizada en los siguientes dominios: dominio tiempo, dominio frecuencia, dominio frecuencia-tiempo; cada uno de éstos aportará diferente información del proceso de degradación y del fallo del rodamiento. En las investigaciones analizadas, se ha identificado que, en algunos casos, se ha experimentado en los tres dominios, en dos dominios diferentes y en un solo dominio. Los dominios más estudiados son el dominio tiempo y tiempo-frecuencia.

*¿Qué métodos de extracción de características de una señal de vibraciones se han empleado para la predicción de vida útil remanente en rodamientos y cuáles son las técnicas o extractores aplicados?*

Los métodos de extracción de características, pueden clasificarse de manera general en dos categorías: de forma automática, en este caso el 44% de los artículos revisados optaron por este método (ver Figura 7). Por otra parte, cuando se emplea un algoritmo de DL para tal propósito, la extracción es automática, la mayoría de los estudios revisados eligieron éste método, dado que la principal ventaja, es que no se requiere del criterio experto para la extracción de las características, como es el caso de la extracción manual.

**Figura 7**

Métodos de extracción de características



### ***Modelos de predicción se han empleado para el cálculo de la vida útil remanente en rodamientos***

Entre los algoritmos que las investigaciones han empleado para la predicción de RUL, se encuentran: deep neural network model, Deep separable convolutional network (DSCN), Regresión lineal, CNN, PSO-IMSSVR, Feedback extreme learning machine (FELM) y LSTM

### ***Métricas se han empleado para evaluar y cuál es el valor del desempeño de los modelos que predicen la vida útil remanente en rodamientos***

Los modelos propuestos para la predicción de vida útil residual en rodamientos, evalúan su rendimiento, empleando métricas de evaluación de modelos de regresión, entre ellas: RMSE: Root Mean Square Error; MAPE: Mean Absolute Percentage Error; MAE: Mean Absolute Error. La Tabla 5, indica los valores correspondientes a las métricas empleadas por cada estudio.

**Tabla 5**

*Métricas y rendimiento de los modelos de predicción registrados en los estudios analizados.*

No.	Fuente	Título del artículo	Métrica
1		A Hybrid Prognostics Approach for Estimating Remaining Useful Life of Rolling Element Bearings. (B. Wang et al., 2020)	MAE=6.1
2		A Deep Learning Method for Bearing Fault Diagnosis Based on Time-frequency Image. (Xiang Li et al., 2019b)	MAPE=8.9
3		Prediction of Bearing Remaining Useful Life With Deep Convolution Neural Network. (Ren et al., 2018)	RMSE=33.3 Media del índice de evaluación=0.43
4	IEEE Xplore	Predicting Remaining Useful Life of Rolling Bearings Based on Deep Feature Representation and Transfer Learning. (Mao et al., 2020)	RMSE=28.5
5	IEEE Xplore	Simultaneous Bearing Fault Recognition and Remaining Useful Life Prediction Using Joint-Loss Convolutional Neural Network. (R. Liu et al., 2020)	RMSE=32.1
6		Feature Extraction for Data-Driven Remaining Useful Life Prediction of Rolling Bearings. (H. Zhao et al., 2021)	MAPE=7.2
7		A Deep Learning-Based Remaining Useful Life Prediction Approach for Bearings. (C. Cheng, Ma, et al., 2020)	MAE=6.5
8		Roller Bearing Degradation Assessment Based on a Deep MLP Convolution Neural Network Considering Outlier Regions. (D. Zhang et al., 2020)	MAPE=8.4
9		Bearing Performance Degradation Assessment Based on Ensemble Empirical Mode Decomposition and Affinity Propagation Clustering. (Xu et al., 2019)	MAE=7.1
10		Remaining Useful Life Prediction of Rolling Element Bearings Using Supervised Machine Learning. (Xiaochuan Li et al., 2019)	RMSE=40.1
11		Sparse Optimistic Based on Lasso-LSQR and Minimum Entropy De-Convolution with FARIMA for the Remaining Useful Life Prediction of Machinery. (B. Wu et al., 2018)	MAE=5.9
12	MDPI	GMPSO-VMD Algorithm and Its Application to Rolling Bearing Fault Feature Extraction. (Ding et al., 2020)	RMSE=29.4
13	MDPI	A Double-Channel Hybrid Deep Neural Network Based on CNN and BiLSTM for Remaining Useful Life Predictive. (C. Zhao et al., 2020)	MAPE=7.7
14	MDPI	A Reliable Prognosis Approach for Degradation Evaluation of Rolling Bearing Using MCLSTM. (Huang et al., 2020)	RMSE=30.5
15	MDPI	An Autoencoder Gated Recurrent Unit for Remaining Useful Life Prediction. (Y.-W. Lu et al., 2020)	MAE=6.3

**Tabla 5**

*Métricas y rendimiento de los modelos de predicción registrados en los estudios analizados (continuación)*

No.	Fuente	Título del artículo	Métrica
16		An Ensemble Learning and RUL Prediction Method Based on Bearings Degradation Indicator Construction. (Tian & Wang, 2020)	RMSE=30.6
17		Bearing Remaining Useful Life Prediction Based on Naive Bayes and Weibull Distributions. (N. Zhang et al., 2018)	RMSE=35.8
18		Bearing remaining useful life estimation using an adaptive data-driven model based on health state change point identification and K-means clustering. (Singh et al., 2020)	MAPE=8.3
19		An integrated approach to bearing prognostics based on EEMD-multi feature extraction, Gaussian mixture models and Jensen-Renyi divergence. (Rai & Upadhyay, 2018)	MAE=8.2
20		Sparse auto-encoder with regularization method for health indicator construction and remaining useful life prediction of rolling bearing. (She et al., 2020)	RMSE=29.4
21	WoS	Remaining useful life prediction of rolling bearing using fractal theory. (Meng et al., 2020)	RMSE=37.5
22		A novel health indicator based on the Lyapunov exponent, a probabilistic self - organizing map, and the Gini-Simpson index for calculating the RUL of bearings. (Rai & Kim, 2020)	MAPE=9.1
23		Predicting remaining useful life of rolling bearings based on deep feature representation and long short-term memory neural network. (Mao et al., 2018)	MAE=8.4
24		Remaining useful life prediction of rolling element bearings using degradation feature based on amplitude decrease at specific frequencies. (An et al., 2018)	RMSE=35.6
25		Estimation of Remaining Useful Life of Rolling Element Bearings Using Wavelet Packet Decomposition and Artificial Neural Network. (Rohani Bastami et al., 2019)	MAE=6
26	Springer	Remaining Life Prediction Method for Rolling Bearing Based on the Long Short-Term Memory Network. (F. Wang et al., 2019)	RMSE=29.9
27		Physics-based intelligent prognosis for rolling bearing with fault feature extraction. (Y. Lu et al., 2018)	MAE=6.2
28		A method for constructing rolling bearing lifetime health indicator based on multi-scale convolutional neural networks. (C. Wu et al., 2019)	RMSE=42.7
29		Deep learning-based remaining useful life estimation of bearings using multi-scale feature extraction. (Xiang Li et al., 2019a)	MAPE=6.9
30		A novel deep learning method based on attention mechanism for bearing remaining useful life prediction. (Chen et al., 2020)	MAE=5.8
31	Science Direct	A two-stage method based on extreme learning machine for predicting the remaining useful life of rolling-element bearings. (Pan et al., 2020)	RMSE=30.7
32		Bearing remaining useful life prediction using support vector machine and hybrid degradation tracking model. (Yan et al., 2020)	RMSE=40.2
33		A convolutional neural network based degradation indicator construction and health prognosis using bidirectional long short-term memory network for rolling bearings. (Y. Cheng et al., 2021)	MAPE=8.5
34		A Koopman operator approach for machinery health monitoring and prediction with noisy and low-dimensional industrial time series. (C. Cheng, Ding, et al., 2020)	MAE=7.7
35	Taylor y Francis	Performance degradation assessment of rolling bearing based on convolutional neural network and deep long-short term memory network. (Z. Wang et al., 2020)	RMSE=29.5

*Cuántos estudios presentan como parte de la evaluación del desempeño del modelo, el valor de la desviación estándar*

El 60% de los estudios analizados no presentan el valor de desviación estándar o el valor de intervalo de confianza, conocer esta medida es importante, ya que permite valorar el rango de fluctuación del error del modelo.

#### 4. Discusión

Para asegurar la confiabilidad de este trabajo se ha adoptado el protocolo recomendado por (Kitchenham & Charters, 2007), en las diferentes etapas. Teniendo como punto focal el objetivo de la investigación, se formularon las preguntas de investigación en la temática: Predicción de la vida útil remanente en rodamientos, aplicando algoritmos de Machine Learning. Esta SLR solo investiga artículos publicados en el periodo 01-01-2018 y 30-11-2021, con más de 5 citas enfocados en el tema de estudio, por lo que luego de la fecha señalada pudieron haberse publicado artículos con técnicas innovadoras, pero que no fueron estudiados por no haber estado publicados aún. Los resultados se derivan de extracción de información de los artículos de seleccionados, para lo cual se diseñó un formato, con campos específicos que contribuyeron a dar respuesta a las preguntas de investigación y a realizar la siguiente discusión.

Sobre los problemas que abordan los diferentes estudios, queda claro que la extracción de características representativas de la señal de vibraciones, es el problema al que mayor esfuerzo se le dedica; esto es de esperarse dado que mientras mayor es el número de características, más complejo es el modelo que se requiere para solucionar el problema que se investiga. Además, dado que las características deben ser extraídas de una señal de vibraciones en esta existe ruido ocasiona por diferentes factores, lo que ocasiona que el problema sea aún más difícil de resolver; a esto se suman los diferentes dominios: tiempo, frecuencia, tiempo-frecuencia, de los cuales las características pueden ser extraídas. No debe dejarse a un lado el hecho de que cuando la extracción de características es manual, se requiere un criterio experto. Por otra parte, algunos estudios presentan como propuesta para solucionar este problema el uso de algoritmos de Deep Learning, que ha demostrado ser efectivo en tomar características representativas del espectro de vibraciones; sin embargo, esto acarrea nuevos desafíos, dado que se incrementa la complejidad de los modelos y la cantidad de datos que se requiere es considerablemente grande, así como el costo computacional. Queda como brecha de investigación, buscar soluciones eficientes bajo el contexto real de la industria.

En lo referente al conjunto de datos que se ha empleado para entrenar, validar y probar los modelos de predicción de vida útil remanente en rodamientos, PRONOSTIA Platform es la base de datos más usada que reportan los artículos estudiados, esta provee datos suficientes para usar algoritmos de DL; sin embargo, se cuestiona el hecho de que son datos tomados en laboratorio sometidos a pruebas de vida acelerada, lo cual podría repercutir en obtener modelos no generalizables a la práctica. El hecho de que sea una base de datos muy usada conlleva a que las investigaciones que emplean el mismo dataset puedan comparar el desempeño de los modelos propuestos.

Los modelos de predicción que más se han empleado para el cálculo de la vida útil remanente en rodamientos, corresponden a algoritmos de Deep Learning, que fueron valorados en algunos casos con dos métricas.

## 5. Conclusiones

- De la revisión sistemática de la literatura respecto a la predicción de vida útil remanente en rodamientos aplicando Machine Learning, se identificó que existen tres desafíos por superar, entre los cuales están: la extracción de características representativas de la señal de vibraciones, la identificación del inicio de estado de degradación y la implementación de modelos generalizables. Los estudios analizados, indicaron que en los últimos años se están empleando modelos de Deep Learning, por la capacidad que tienen para superar el problema de la extracción de características, sin embargo, esto conlleva nuevos retos a abordarse, como la cantidad de datos y la capacidad computacional que demandan estos modelos.

## 6. Conflicto de intereses

Los autores declaran que no existe conflicto de intereses en relación con el artículo presentado.

## 7. Declaración de contribución de los autores

Todos los autores contribuyeron significativamente en la elaboración del artículo.

## 8. Costos de financiamiento

La presente investigación fue financiada en su totalidad con fondos propios de los autores

## 9. Referencias Bibliográficas

- An, D., Choi, J.-H., & Kim, N. H. (2018). Remaining useful life prediction of rolling element bearings using degradation feature based on amplitude decrease at specific frequencies. *Structural Health Monitoring*, 17(5), 1095–1109.  
<https://doi.org/10.1177/1475921717736226>
- Biggio, L., & Kastanis, I. (2020). Prognostics and Health Management of Industrial Assets: Current Progress and Road Ahead. *Frontiers in Artificial Intelligence*, 3(November), 1–24. <https://doi.org/10.3389/frai.2020.578613>
- Cakir, M., Guvenc, M. A., & Mistikoglu, S. (2021). The experimental application of popular machine learning algorithms on predictive maintenance and the design of IIoT based condition monitoring system. *Computers and Industrial Engineering*, 151, 106948. <https://doi.org/10.1016/j.cie.2020.106948>

www.concienciadigital.org

Chen, Y., Peng, G., Zhu, Z., & Li, S. (2020). A novel deep learning method based on attention mechanism for bearing remaining useful life prediction. *Applied Soft Computing*, 86, 105919. <https://doi.org/10.1016/j.asoc.2019.105919>

Cheng, C., Ding, J., & Zhang, Y. (2020). A Koopman operator approach for machinery health monitoring and prediction with noisy and low-dimensional industrial time series. *Neurocomputing*, 406, 204–214.  
<https://doi.org/10.1016/j.neucom.2020.04.005>

Cheng, C., Ma, G., Zhang, Y., Sun, M., Teng, F., Ding, H., & Yuan, Y. (2020). A Deep Learning-Based Remaining Useful Life Prediction Approach for Bearings. *IEEE/ASME Transactions on Mechatronics*, 25(3), 1243–1254.  
<https://doi.org/10.1109/TMECH.2020.2971503>

Cheng, Y., Hu, K., Wu, J., Zhu, H., & Shao, X. (2021). A convolutional neural network based degradation indicator construction and health prognosis using bidirectional long short-term memory network for rolling bearings. *Advanced Engineering Informatics*, 48, 101247. <https://doi.org/10.1016/j.aei.2021.101247>

Cinar, Z. M., Nuhu, A. A., Zeeshan, Q., Korhan, O., Asmael, M., & Safaei, B. (2020). Machine learning in predictive maintenance towards sustainable smart manufacturing in industry 4.0. *Sustainability (Switzerland)*, 12(19).  
<https://doi.org/10.3390/su12198211>

Dalzochio, J., Kunst, R., Pignaton, E., Binotto, A., Sanyal, S., Favilla, J., & Barbosa, J. (2020). Machine learning and reasoning for predictive maintenance in Industry 4.0: Current status and challenges. *Computers in Industry*, 123, 103298.  
<https://doi.org/10.1016/j.compind.2020.103298>

Ding, J., Huang, L., Xiao, D., & Li, X. (2020). GMPSO-VMD Algorithm and Its Application to Rolling Bearing Fault Feature Extraction. *Sensors*, 20(7), 1946.  
<https://doi.org/10.3390/s20071946>

Huang, G., Li, H., Ou, J., Zhang, Y., & Zhang, M. (2020). A Reliable Prognosis Approach for Degradation Evaluation of Rolling Bearing Using MCLSTM. *Sensors*, 20(7), 1864. <https://doi.org/10.3390/s20071864>

Kitchenham, B. A., & Charters, S. (2007). *Guidelines for performing Systematic Literature Reviews in Software Engineering. EBSE Technical Report EBSE-2007-01. School of Computer Science and Mathematics, Keele University. October 2021, 2007.*  
[https://legacyfileshare.elsevier.com/promis\\_misc/525444systematicreviewsguide.pdf](https://legacyfileshare.elsevier.com/promis_misc/525444systematicreviewsguide.pdf)

Li, Xiang, Zhang, W., & Ding, Q. (2019a). Deep learning-based remaining useful life estimation of bearings using multi-scale feature extraction. *Reliability Engineering and System Safety*, 182(October 2018), 208–218.  
<https://doi.org/10.1016/j.ress.2018.11.011>

www.concienciadigital.org

- Li, Xiang, Zhang, W., & Ding, Q. (2019b). Deep learning-based remaining useful life estimation of bearings using multi-scale feature extraction. *Reliability Engineering & System Safety*, 182, 208–218. <https://doi.org/10.1016/j.ress.2018.11.011>
- Li, Xiaochuan, Elasha, F., Shanbr, S., & Mba, D. (2019). Remaining Useful Life Prediction of Rolling Element Bearings Using Supervised Machine Learning. *Energies*, 12(14), 2705. <https://doi.org/10.3390/en12142705>
- Liu, R., Yang, B., & Hauptmann, A. G. (2020). Simultaneous Bearing Fault Recognition and Remaining Useful Life Prediction Using Joint-Loss Convolutional Neural Network. *IEEE Transactions on Industrial Informatics*, 16(1), 87–96. <https://doi.org/10.1109/TII.2019.2915536>
- Liu, Y., He, B., Liu, F., Lu, S., Zhao, Y., & Zhao, J. (2016). Remaining useful life prediction of rolling bearings using PSR, JADE, and extreme learning machine. *Mathematical Problems in Engineering*, 2016. <https://doi.org/10.1155/2016/8623530>
- Liu, Z., Zuo, M. J., & Qin, Y. (2016). Remaining useful life prediction of rolling element bearings based on health state assessment. *Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science*, 230(2), 314–330. <https://doi.org/10.1177/0954406215590167>
- Lu, Y.-W., Hsu, C.-Y., & Huang, K.-C. (2020). An Autoencoder Gated Recurrent Unit for Remaining Useful Life Prediction. *Processes*, 8(9), 1155. <https://doi.org/10.3390/pr8091155>
- Lu, Y., Li, Q., & Liang, S. Y. (2018). Physics-based intelligent prognosis for rolling bearing with fault feature extraction. *The International Journal of Advanced Manufacturing Technology*, 97(1–4), 611–620. <https://doi.org/10.1007/s00170-018-1959-0>
- Mao, W., He, J., Tang, J., & Li, Y. (2018). Predicting remaining useful life of rolling bearings based on deep feature representation and long short-term memory neural network. *Advances in Mechanical Engineering*, 10(12), 1–18. <https://doi.org/10.1177/1687814018817184>
- Mao, W., He, J., & Zuo, M. J. (2020). Predicting Remaining Useful Life of Rolling Bearings Based on Deep Feature Representation and Transfer Learning. *IEEE Transactions on Instrumentation and Measurement*, 69(4), 1594–1608. <https://doi.org/10.1109/TIM.2019.2917735>
- Meng, Z., Li, J., Yin, N., & Pan, Z. (2020). Remaining useful life prediction of rolling bearing using fractal theory. *Measurement*, 156, 107572. <https://doi.org/10.1016/j.measurement.2020.107572>
- Mushtaq, S., Manjurul Islam, M. M., & Sohaib, M. (2021). Deep learning aided data-driven fault diagnosis of rotatory machine: A comprehensive review. *Energies*, 14(16). <https://doi.org/10.3390/en14165150>

Nectoux, P., Gouriveau, R., Medjaher, K., Ramasso, E., Chebel-morello, B., Zerhouni, N., Varnier, C., Nectoux, P., Gouriveau, R., Medjaher, K., Ramasso, E., Chebel-morello, B., Nectoux, P., Gouriveau, R., Medjaher, K., Ramasso, E., Morello, B., Zerhouni, N., & Varnier, C. (2012). PRONOSTIA : An experimental platform for bearings accelerated degradation tests . To cite this version : HAL Id : hal-00719503 PRONOSTIA : An Experimental Platform for Bearings Accelerated Degradation Tests. *IEEE International Conference on Prognostics and Health Management, PHM'12., Jun 2012, Denver, Col- Orado, United States.*, 1–8. <https://hal.science/hal-00719503>

Pan, Z., Meng, Z., Chen, Z., Gao, W., & Shi, Y. (2020). A two-stage method based on extreme learning machine for predicting the remaining useful life of rolling-element bearings. *Mechanical Systems and Signal Processing*, 144, 106899. <https://doi.org/10.1016/j.ymssp.2020.106899>

Quatrini, E., Costantino, F., Di Gravio, G., & Patriarca, R. (2020). Machine learning for anomaly detection and process phase classification to improve safety and maintenance activities. *Journal of Manufacturing Systems*, 56(November 2019), 117–132. <https://doi.org/10.1016/j.jmsy.2020.05.013>

Rai, A., & Kim, J.-M. (2020). A novel health indicator based on the Lyapunov exponent, a probabilistic self-organizing map, and the Gini-Simpson index for calculating the RUL of bearings. *Measurement*, 164, 108002. <https://doi.org/10.1016/j.measurement.2020.108002>

Rai, A., & Upadhyay, S. H. (2018). An integrated approach to bearing prognostics based on EEMD-multi feature extraction, Gaussian mixture models and Jensen-Rényi divergence. *Applied Soft Computing*, 71, 36–50. <https://doi.org/10.1016/j.asoc.2018.06.038>

Ren, L., Sun, Y., Wang, H., & Zhang, L. (2018). Prediction of Bearing Remaining Useful Life With Deep Convolution Neural Network. *IEEE Access*, 6, 13041–13049. <https://doi.org/10.1109/ACCESS.2018.2804930>

Rohani Bastami, A., Aasi, A., & Arghand, H. A. (2019). Estimation of Remaining Useful Life of Rolling Element Bearings Using Wavelet Packet Decomposition and Artificial Neural Network. *Iranian Journal of Science and Technology, Transactions of Electrical Engineering*, 43(S1), 233–245. <https://doi.org/10.1007/s40998-018-0108-y>

She, D., Jia, M., & Pecht, M. G. (2020). Sparse auto-encoder with regularization method for health indicator construction and remaining useful life prediction of rolling bearing. *Measurement Science and Technology*, 31(10), 105005. <https://doi.org/10.1088/1361-6501/ab8c0f>

Singh, J., Darpe, A. K., & Singh, S. P. (2020). Bearing remaining useful life estimation using an adaptive data-driven model based on health state change point identification and K -means clustering. *Measurement Science and Technology*,

www.concienciadigital.org

31(8), 085601. <https://doi.org/10.1088/1361-6501/ab6671>

Tian, Q., & Wang, H. (2020). An Ensemble Learning and RUL Prediction Method Based on Bearings Degradation Indicator Construction. *Applied Sciences*, 10(1), 346. <https://doi.org/10.3390/app10010346>

Wang, B., Lei, Y., Li, N., & Li, N. (2020). A Hybrid Prognostics Approach for Estimating Remaining Useful Life of Rolling Element Bearings. *IEEE Transactions on Reliability*, 69(1), 401–412. <https://doi.org/10.1109/TR.2018.2882682>

Wang, F., Liu, X., Deng, G., Yu, X., Li, H., & Han, Q. (2019). Remaining Life Prediction Method for Rolling Bearing Based on the Long Short-Term Memory Network. *Neural Processing Letters*, 50(3), 2437–2454. <https://doi.org/10.1007/s11063-019-10016-w>

Wang, J., Mo, Z., Zhang, H., & Miao, Q. (2019). A Deep Learning Method for Bearing Fault Diagnosis Based on Time-Frequency Image. *IEEE Access*, 7, 42373–42383. <https://doi.org/10.1109/ACCESS.2019.2907131>

Wang, Z., Ma, H., Chen, H., Yan, B., & Chu, X. (2020). Performance degradation assessment of rolling bearing based on convolutional neural network and deep long-short term memory network. *International Journal of Production Research*, 58(13), 3931–3943. <https://doi.org/10.1080/00207543.2019.1636325>

Wu, B., Gao, Y., Feng, S., & Chanwimalueang, T. (2018). Sparse Optimistic Based on Lasso-LSQR and Minimum Entropy De-Convolution with FARIMA for the Remaining Useful Life Prediction of Machinery. *Entropy*, 20(10), 747. <https://doi.org/10.3390/e20100747>

Wu, C., Feng, F., Wu, S., Jiang, P., & Wang, J. (2019). A method for constructing rolling bearing lifetime health indicator based on multi-scale convolutional neural networks. *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, 41(11), 526. <https://doi.org/10.1007/s40430-019-2010-6>

Xu, F., Song, X., Tsui, K.-L., Yang, F., & Huang, Z. (2019). Bearing Performance Degradation Assessment Based on Ensemble Empirical Mode Decomposition and Affinity Propagation Clustering. *IEEE Access*, 7, 54623–54637. <https://doi.org/10.1109/ACCESS.2019.2913186>

Yan, M., Wang, X., Wang, B., Chang, M., & Muhammad, I. (2020). Bearing remaining useful life prediction using support vector machine and hybrid degradation tracking model. *ISA Transactions*, 98, 471–482. <https://doi.org/10.1016/j.isatra.2019.08.058>

Zhang, D., Stewart, E., Ye, J., Entezami, M., & Roberts, C. (2020). Roller Bearing Degradation Assessment Based on a Deep MLP Convolution Neural Network Considering Outlier Regions. *IEEE Transactions on Instrumentation and Measurement*, 69(6), 2996–3004. <https://doi.org/10.1109/TIM.2019.2929669>

www.concienciadigital.org

Zhang, N., Wu, L., Wang, Z., & Guan, Y. (2018). Bearing Remaining Useful Life Prediction Based on Naive Bayes and Weibull Distributions. *Entropy*, 20(12), 944. <https://doi.org/10.3390/e20120944>

Zhao, C., Huang, X., Li, Y., & Yousaf Iqbal, M. (2020). A Double-Channel Hybrid Deep Neural Network Based on CNN and BiLSTM for Remaining Useful Life Prediction. *Sensors*, 20(24), 7109. <https://doi.org/10.3390/s20247109>

Zhao, H., Liu, H., Jin, Y., Dang, X., & Deng, W. (2021). Feature Extraction for Data-Driven Remaining Useful Life Prediction of Rolling Bearings. *IEEE Transactions on Instrumentation and Measurement*, 70, 1–10. <https://doi.org/10.1109/TIM.2021.3059500>

El artículo que se publica es de exclusiva responsabilidad de los autores y no necesariamente reflejan el pensamiento de la **Revista Conciencia Digital**.



El artículo queda en propiedad de la revista y, por tanto, su publicación parcial y/o total en otro medio tiene que ser autorizado por el director de la **Revista Conciencia Digital**.



#### Indexaciones

