

# INDUSTRIAL IoT. MACHINE LEARNING EN LA INDUSTRIA 4.0

David García Rodríguez

Estudiante de Grado de Ingeniería Mecánica en l'Escola Politècnica Superior  
 d'Enginyeria de Vilanova i la Geltrú de la Universitat Politècnica de Catalunya.

## Resumen

La llegada de la cuarta revolución industrial ha otorgado un gran protagonismo al Machine Learning (ML), que permite abordar desafíos de fabricación como el incremento de calidad y la optimización de los procesos.

El objetivo principal de este estudio es destacar la importante herramienta en la que se ha convertido el ML. Para lograrlo, se divide el trabajo en dos partes. En primer lugar, se contextualiza la situación actual del ML y las principales técnicas. En segundo lugar, se revisan 45 casos donde se aplican algoritmos de ML en el ámbito de la ingeniería mecánica.

Tras el análisis de los estudios se observa que el uso de técnicas de ML proporciona grandes resultados de precisión y fiabilidad en diagnóstico de fallos, pronóstico de defectos y optimización de sistemas.

## Palabras clave

Machine learning, Industria 4.0, Big Data, Caso de uso, Ingeniería mecánica, Predicción, Diagnóstico, Optimización.

## 1. Introducción

Desde tiempos remotos los humanos han tenido tendencia a buscar avances tecnológicos, haciendo así que la evolución de la historia de la humanidad haya ido siempre ligada a la evolución de la historia de la tecnología y más concretamente, a la evolución de las máquinas [1].

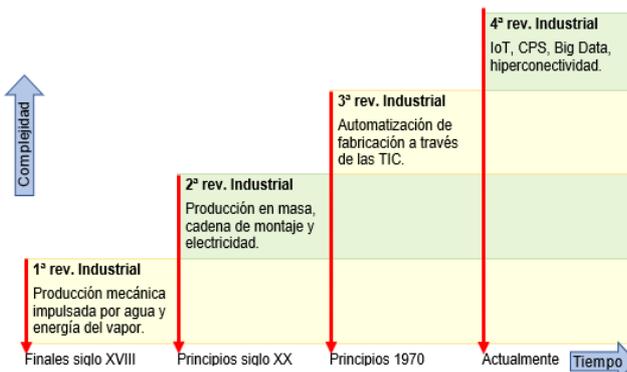


Fig. 1. Evolución de las revoluciones industriales (fuente propia)

Nos remontamos a finales del siglo XVIII, cuando la invención de máquinas basadas en el aprovechamiento de energía generada por vapor da pie a la primera revolución industrial [Figura 1]. Posteriormente, a principios del siglo XX, la segunda revolución industrial viene marcada por la introducción de la electricidad y el petróleo como fuente energética para la producción en masa, dando lugar a la cadena de producción y la división de trabajo. Es a principios del año 1970 cuando estalla la tercera revolución industrial, que destaca por la automatización de procesos basada en sistemas electrónicos y tecnologías de la información (TIC). Hoy en día la humanidad se encuentra a las puertas de la cuarta revolución industrial [2, 3].

La idea de industria 4.0 apareció por primera vez en el panorama mundial en la feria industrial alemana de Hannover celebrada el año 2011 [4]. Esta nueva revolución tiene como objetivo la mejora de calidad de los productos, la optimización de los procesos y la reducción del coste estimado de estos, y se basa en el incremento masivo de datos (Big Data) como consecuencia de la implementación de los sensores y el desarrollo del internet de las cosas (IoT).

Un año más tarde de la aparición del término industria 4.0, en el 2012, surge derivado de IoT el concepto IIoT (internet de las cosas industrial). IIoT se refiere a una red de dispositivos industriales conectados por tecnologías de comunicaciones con el propósito de monitorear, recopilar, intercambiar y analizar ideas para impulsar decisiones empresariales más inteligentes y rápidas, es decir, para mejorar la eficiencia de los procesos industriales y de fabricación [5].

La inteligencia artificial (AI), los sistemas ciberfísicos (CPS), la acumulación masiva de información (Big Data) y el uso de algoritmos para automatizar procesos mediante aprendizaje automático (ML) son otros de los elementos fundamentales de la novedosa industria 4.0.

La llegada de la industria 4.0, la gran cantidad de datos disponibles, el alto poder de computación de los dispositivos y la gran capacidad de almacenamiento de los mismos, son la causa de que las técnicas de ML se hayan

convertido en una solución atractiva para abordar desafíos de fabricación. El ML ofrece una gran cantidad de herramientas para extraer información de datos que puede traducirse en conocimiento para enriquecer y transformar las aplicaciones industriales.

En este trabajo se presenta una visión general de las técnicas de aprendizaje automático y se realiza una revisión de la literatura científica para analizar como las técnicas de ML se están convirtiendo en herramientas clave en el entorno industrial actual.

## 2. Motivación

La idea de elaborar este estudio nace de la lectura del artículo de Rogalewicz et al. [6] donde se revisan diferentes metodologías de minería de datos (DM) en el ámbito de la ingeniería mecánica. La lectura de Stanula et al. [7] y Wuest et al. [8], que tratan las técnicas de ML y el potencial que tienen en la industria manufacturera, sirven para confirmar el interés del trabajo.

La motivación principal de este trabajo es destacar el peso que se le está asignando a la automatización y a la inteligencia artificial en los procesos industriales. Destacar la importante herramienta en la que se ha convertido el ML por su capacidad para diagnosticar y clasificar fallos, pronosticar defectos y optimizar sistemas. Y concienciar de la necesidad de añadir en el currículo académico de un ingeniero nociones básicas sobre esta novedosa herramienta.

## 3. Metodología

El trabajo se ha dividido en dos partes. Por un lado, se encuentra el capítulo de Machine Learning donde se contextualiza el ML. Se presenta el ciclo de vida de los datos, las técnicas de DM más conocidas, los tipos de aprendizaje automático y los algoritmos de ML más utilizados.

Por otro lado, se recogen y sintetizan 45 casos donde se están aplicando técnicas de ML en el ámbito de la ingeniería mecánica. Estos casos se clasifican, dependiendo del objetivo de la aplicación de la técnica, entre diagnóstico y clasificación de fallos, predicción y pronóstico de defectos y optimización de sistemas.

La recopilación de bibliografía se ha llevado a cabo en las principales bases de datos (IEEE Xplore, ScienceDirect, Google Scholar, SpringerLink y ResearchGate). Para ello, se han utilizado las palabras clave “Machine Learning”, “Data Mining”, “Industria 4.0”, “Engineering”, “Mechanical Engineering”, “Use case”, “application”, “prognosis fault”, “optimization” y “fault diagnosis”.

Para profundizar y completar la información, durante la elaboración del proyecto se han identificado estudios a través de referencias hechas en artículos ya revisados.

## 4. Machine learning

El ML proporciona un poderoso marco de procesamiento de información capaz de enriquecer, y posiblemente incluso transformar, las líneas actuales de investigación en ingeniería mecánica y aplicaciones industriales [9].

El objetivo de las técnicas de ML varía en función del tipo de aprendizaje. Este objetivo va desde proporcionar a las máquinas la capacidad de predecir o generar patrones que describan relaciones, hasta centrarse en proporcionar la capacidad de aprender, adaptarse a los cambios y resolver problemas sin haber sido programadas específicamente para ello, tal y como podría hacer un humano. El ML se aplica en diferentes áreas de fabricación, como, por ejemplo, la optimización, el control y la resolución de problemas. La Figura 2 muestra el proceso de aplicación de ML en la ingeniería mecánica.

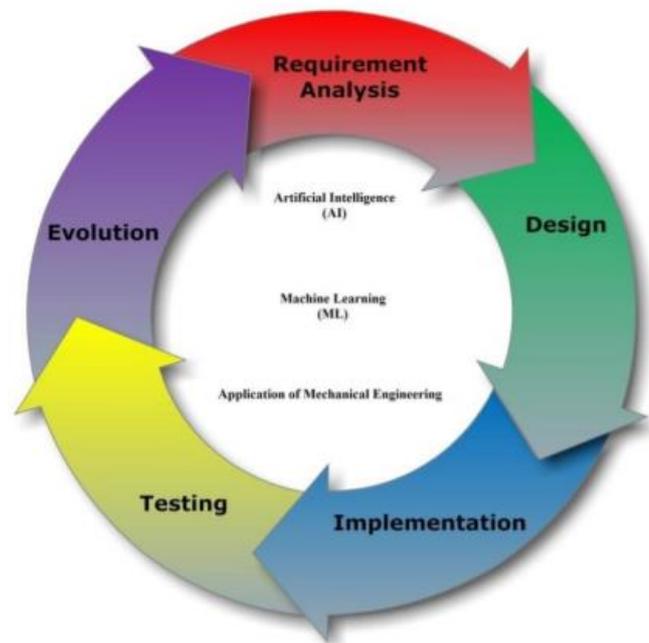


Fig. 2. Proceso de aplicación de ML/AI en ingeniería mecánica (Extraído de [10])

La inteligencia artificial (AI) incluye entre una de sus ramas el ML. El término AI apareció en la década de los 50 del siglo pasado, cuando se cuestionó la posibilidad de describir la inteligencia de modo tan preciso que se pudiese construir una máquina capaz de simularla. Es decir, la AI es el conjunto de técnicas, métodos, herramientas y metodologías que nos ayudan a construir sistemas que se comportan de manera similar a un humano en la resolución de problemas concretos. Los objetivos principales de la AI son modelar conocimiento, formalizar los modelos, programar los operadores formales e implementar físicamente el soporte de esos programas [11, 12].

El ML dispone del Deep Learning (DL) como una de las subcategorías de este. El DL es un término que se empezó a utilizar en 2006 para explicar nuevas técnicas que

proporcionan herramientas analíticas avanzadas capaces de procesar y analizar grandes cantidades de datos [13].

El rendimiento de los algoritmos de ML depende directamente de la cantidad y calidad del conjunto de datos. Es decir, el aprendizaje de estos algoritmos puede verse condicionado por los datos de los que disponga. En la última década ha aumentado de forma exponencial la cantidad de datos recopilados. Este suceso es el conocido Big Data.

El término Big Data hace referencia a la acumulación masiva de datos, llevado al punto de superar la capacidad de las herramientas tradicionales para ser registrados, gestionados y procesados en un tiempo razonable. Por lo tanto, un conjunto de datos se le categoriza dentro de Big Data cuando es demasiado grande para ser manejado de forma apropiada por los programas convencionales [14]. Los métodos usados para extraer conocimiento de estos grandes conjuntos de datos son los llamados métodos de Data Mining (DM), basados en estadística matemática y/o en inteligencia artificial.

#### 4.1. Data Mining

El hecho de capturar y analizar eficientemente grandes cantidades de datos tiene como consecuencia directa la mejora de calidad y productividad respecto a los sistemas tradicionales. La minería de datos es una técnica interdisciplinaria que se está volviendo popular en varias ramas de la ingeniería, en especial en la ingeniería mecánica, ya que permite descubrir información oculta en los conjuntos de datos y proporcionar soluciones rápidas para obtener análisis de profundidad sobre productos. En general, las técnicas de DM son capaces de analizar grandes cantidades de datos de forma efectiva en un período de tiempo reducido, siendo esto una tarea complicada para el ser humano [15, 16].

Para poder utilizar los datos con éxito es necesario que se procesen, de tal forma que se traduzcan en sentido y contexto de información concretos. El ciclo de vida de los datos consta de ocho etapas:

1. Recopilación de datos. El punto inicial donde se recogen datos de diferentes fuentes, especialmente de sensores.
2. Almacenamiento de datos. Los datos se clasifican en estructurados, semiestructurados y datos no estructurados.
3. Preprocesamiento de datos. Se elimina información redundante, engañosa, duplicada e inconsistente.
4. Análisis de datos. Exploración de los datos una vez limpios y simplificados.
5. Aplicación del modelo. Se extrae conocimiento de los datos gracias a algoritmos de ML.

6. Visualización de datos. Hace más fácil la visualización de los resultados.
7. Transmisión de datos. La fluidez continua de datos entre sistemas permite la integración de manera efectiva en recursos de fabricación.
8. Aplicación de datos. Hace posibles acciones de precaución como el mantenimiento preventivo, la clasificación de fallos y la actualización automática.

Para la correcta utilización de los datos, se pueden utilizar diferentes metodologías de DM. Entre las más comunes se encuentran CRISP-DM, KDD, SEMMA y VC-DM.

#### 4.2. Clasificación de algoritmos de ML

Los algoritmos de ML pueden clasificarse según cómo se entrenan los modelos y la forma que tienen de aprender de los datos. Tal y como se muestra en la Figura 3, los algoritmos de ML se pueden clasificar en tres categorías, a saber, aprendizaje supervisado, aprendizaje no supervisado y aprendizaje por refuerzo. A su vez, pueden subclasificarse teniendo en cuenta la función que tienen a la hora de ser aplicados en: algoritmos de clasificación, regresión, clustering y de recompensa [10].

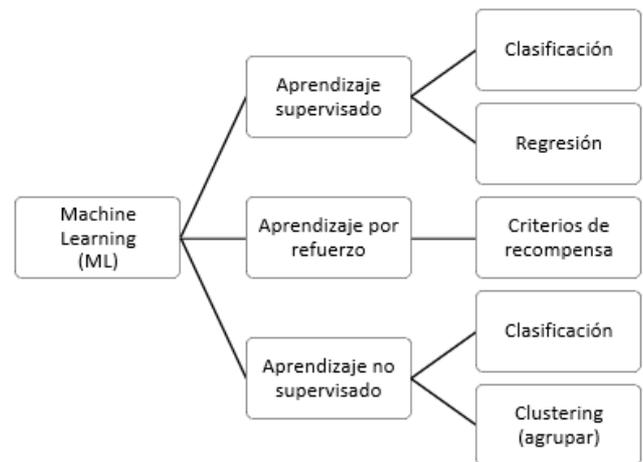


Fig. 3. Clasificación de modelos de ML. (Fuente propia)

En el aprendizaje supervisado, el modelo se entrena con ejemplos de valores de entrada y de salida. Este proceso de aprendizaje se denomina supervisado porque cada dato de entrada tiene asociada una salida (etiqueta). Se basa en descubrir la relación existente entre las variables de entrada y las variables de salida de tal forma que el modelo pueda identificar cuando las predicciones sean falsas. Para entrenar el modelo, se necesita una gran muestra de datos de entrada y de salida y la supervisión de un humano para etiquetar los datos de entrada. Es por eso, que el proceso es posible que sea de coste elevado.

En el aprendizaje no supervisado el sistema también aprende de los datos de entrada, sin embargo, no dispone de datos de salida. Este tipo de aprendizaje se desarrolla creando patrones de similitud entre datos de entrada. La

ventaja de este tipo de aprendizaje respecto el aprendizaje supervisado es que los datos de muestra pueden crearse con muy poco esfuerzo y no necesitas la supervisión de un humano para visualizar y etiquetar. Por ello, y en el contexto del Big Data, los métodos no supervisados tienen cada vez más relevancia.

En modelos de aprendizaje por refuerzo (RL) no se requiere una muestra inicial para entrenar el modelo ya que el agente recibe información interactuando continuamente con el entorno. Los algoritmos de RL se entrenan por recompensas y penalizaciones. Generalmente, los métodos se basan en un sistema de puntuación donde las recompensas se expresan como un aumento de puntos y las penalizaciones como una disminución. RL es muy recomendado para problemas que incluyen compensación de recompensa a largo plazo versus corto plazo [17].

### 4.3. Muestra de algoritmos de ML

Son muchos los algoritmos de ML existentes. Dado que el presente trabajo está centrado en la aplicación de técnicas en el ámbito industrial, a continuación, se presenta la tabla 1, donde se recogen los algoritmos más utilizados en este ámbito.

<b>Aprendizaje supervisado</b>	Clasificación	LR, DT, RF, NN, SVM, KNN, HMM
	Regresión	SLR, MLR, PR, LR, SVM, GPR, MLP,
<b>Aprendizaje no supervisado</b>	Clasificación	CNN, AE, RNN, LSTM, GRU
	Clustering	K-means, NN, IF
<b>Aprendizaje por refuerzo</b>	Criterios de recompensa	RL (Q-learning, Monte-carlo, e-greedy)

Tabla 1. Algoritmos de ML clasificados por tipos. (Fuente propia)

Muchos algoritmos son aplicables tanto para aprendizaje supervisado como para aprendizaje no supervisado (siempre de forma adaptada).

## 5. Estudios de caso

La aplicación de técnicas de ML tiene cada vez más protagonismo para reducir potencialmente los costes de mantenimiento y mejorar la productividad de las empresas.

Entre los beneficios más comunes, los algoritmos de ML potencian el diagnóstico y clasificación de fallos, la predicción y pronóstico de defectos y la optimización de sistemas.

### 5.1. Diagnóstico y clasificación de fallos

La detección temprana y clasificación de los fallos cada vez se considera más importante en la industria. Tener la

capacidad de detectar fallos pronto y saber el motivo por el que se han ocasionado estos fallos puede evitar grandes pérdidas económicas y largos tiempos de inactividad.

Feng Jia et al. [18] propone una red neuronal profunda (DNN) con el objetivo de procesar datos masivos de fallos y proporcionar resultados precisos de diagnóstico en maquinaria rotativa. Tras realizar el estudio se obtienen datos de precisión superiores al 99% y por lo tanto se concluye con éxito.

En los catorce artículos restantes recogidos, también se aprecia que la aplicación de técnicas de ML facilita la obtención de altos valores de precisión en diferentes sectores del ámbito industrial. A continuación, se presenta un gráfico [Fig. 4] donde se muestran los algoritmos mencionados en los estudios de diagnóstico de fallos analizados. Destacar lo común que es el uso de SVM (37%) y CNN (32%).

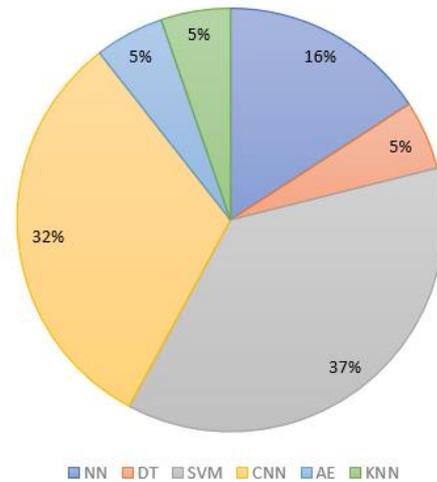


Fig. 4. Utilización de algoritmos de ML en casos de uso de diagnóstico de fallos. (Fuente propia)

### 5.2. Análisis predictivo para el pronóstico de defectos

El mantenimiento preventivo es una de las aplicaciones más importantes de las técnicas de ML. Tener la capacidad de predecir el momento de reemplazo de elementos de falla próxima puede significar la reducción importante de costes de los procesos.

Jing Huang et al. [19] estudia la aplicación de un algoritmo de aprendizaje por refuerzo basado en Q-Learning para la obtención de la política óptima de reemplazo de maquinaria en una línea de producción en serie. El estudio finaliza con la comparación de la política propuesta con otras dos políticas anteriores, demostrando que el coste de mantenimiento por minuto es mucho inferior.

A continuación, en la Figura 5 se muestran los algoritmos que han aparecido citados en el resto de los artículos con relación al pronóstico de defectos. Sobre todo, reflejar la gran variedad de técnicas que pueden ser valoradas, tratándose en muchos de los casos, de algoritmos que han

derivado de las técnicas de aprendizaje automático más tradicionales.

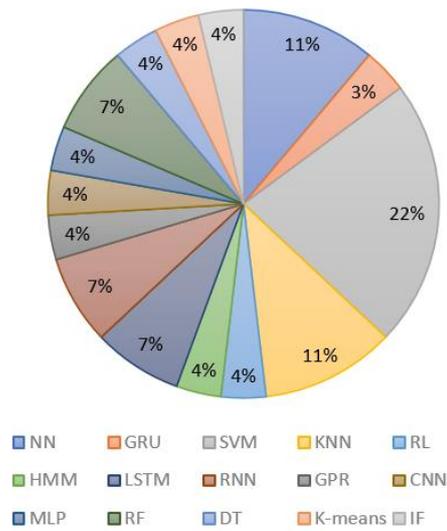


Fig. 5. Utilización de algoritmos de ML en casos de uso de pronóstico de defectos. (Fuente propia)

### 5.3. Optimización de la productividad

Para garantizar la fabricación competitiva, ya sea mejorando la calidad del producto, rentabilizando los procesos o reduciendo el tiempo de fabricación i/o inversión económica, son importantes las técnicas de optimización basadas en algoritmos de ML.

Ivan Zajačko et al. [20] analiza el uso de redes neuronales convolucionales con el objetivo de optimizar el proceso de producción de neumáticos. Se espera que la implementación del método suponga la automatización completa del proceso de control de calidad, detectando con éxito la presencia de defectos.

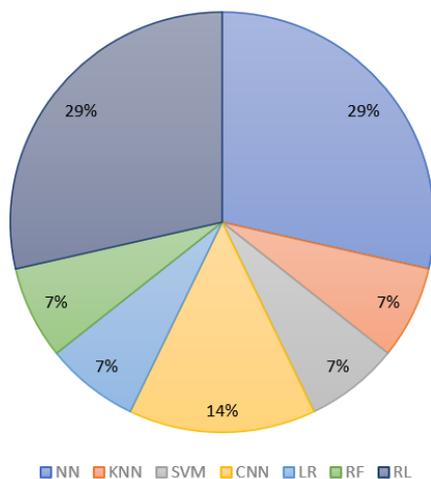


Fig. 6. Utilización de algoritmos de ML en casos de uso de optimización de procesos. (Fuente propia)

En la Figura 6 se muestra la frecuencia de aparición de algoritmos de ML en los artículos de la lista de optimización de procesos. Señalar la gran cantidad de veces

que aparece el algoritmo RL en comparación a los dos apartados anteriores. Se considera que esta diferencia puede ser debida a la actualidad de los artículos seleccionados para este apartado y a la complejidad de los casos planteados.

## 6. Conclusión

Desde 2015 ha crecido exponencialmente el número de publicaciones que presentan técnicas de ML para la mejora de procesos de fabricación o diagnóstico y pronóstico de defectos. Continuamente aparecen algoritmos nuevos, en la mayoría de los casos derivados de los tradicionales, que favorecen la obtención de resultados mejores y, por lo tanto, abren la puerta a nuevos objetivos.

Consideramos que la aplicación de herramientas de ML puede marcar la diferencia a la hora de la toma de decisiones, y que el IoT industrial ya está marcando un antes y un después a pesar de que todavía falte mucho por descubrir. Por este motivo, destacamos la importancia de integrar conocimientos básicos sobre ML en el currículo académico de un ingeniero.

## 7. Agradecimientos

A la familia. Al equipo docente. A Ingrid. Y, sobre todo, especial agradecimiento a Ester.

## Glosario

AE	Autoencoder
CNN	Red neuronal convolucional
DT	Árbol de decisión
GPR	Proceso Gaussiano de regresión
GRU	Unidad recurrente cerrada
HMM	Modelo oculto de Markov
IF	Bosque de aislamiento
KNN	K vecinos más cercanos
LR	Regresión logística
LSTM	Memoria a largo plazo
MLP	Perceptrón multicapa
MLR	Regresión lineal múltiple
NN	Red neuronal
PR	Regresión polinómica
RF	Bosque aleatorio
RL	Aprendizaje reforzado
RNN	Red neuronal recurrente
SLR	Regresión lineal simple
SVM	Máquina de vectores de soporte

## Referencias

- [1] J. L. Muñoz Sanz, J. Echávarri Otero, M. Ceccarelli y P. Lafont Morgado, «The evolution and development of Mechanical Engineering Through Large Cultural Areas,» pp. 69-82, Enero 2009.

- [2] K.-D. Thoben, S. Wiesner y T. Wuest, «"Industrie 4.0" and Smart Manufacturing – A Review of Research Issues and Application Examples,» vol. 11, n° 1, pp. 4-19, 2017.
- [3] D. Preuveeners y E. Ilie-Zudor, «The intelligent industry of the future: A survey on emerging trends, research challenges and opportunities in Industry 4.0,» vol. 9, pp. 287-298, 2017.
- [4] I. Sittón Candanedo, E. Hernández Nieves, S. Rodríguez González, M. T. Santos Martín y A. González Briones, «Machine Learning Predictive Model for Industry 4.0,» vol. 877, pp. 501-510, Julio 2018.
- [5] P. M. LaCasse, W. Otieno y F. P. Maturana, «A Survey of Feature Set Reduction Approaches for Predictive Analytics Models in the Connected Manufacturing Enterprise,» *splsci*, vol. 9, p. 843, 27 Febrero 2019.
- [6] M. Rogalewicz y R. Sika, «Methodologies of knowledge discovery from data and data mining methods in mechanical engineering,» *Management and Production Engineering Review*, vol. 7, n° 4, pp. 97-108, Diciembre 2016.
- [7] P. Stanula, A. Ziegenbein y J. Matternich, «Machine learning algorithms in production: A guideline for efficient data source selection,» de 6th CIRP Global Web Conference – Envisaging the future manufacturing, design, technologies and systems in innovation era (CIRPe 2018), 2018.
- [8] T. Wuest, D. Weimer y C. T. L.-D. Irgens, «Machine learning in manufacturing: advantages, challenges, and applications,» *Production & Manufacturing Research*, vol. 4, n° 1, pp. 23-45, 24 Junio 2016.
- [9] S. L. Brunton, B. R. Noack y K. Petros., «Machine Learning for Fluid Mechanics,» vol. 52, pp. 477-508, 12 Septiembre 2019.
- [10] C. Dhandapani y R. Sivaramakrishnan, «Implementation of Machine Learning (ML) in Mechanical Engineering Application using Artificial Intelligence (AI),» *Science, Technology and Development*, vol. 8, n° 10, p. 93, Octubre 2019.
- [11] J. T. Palma y R. Marin, *Inteligencia artificial. Técnicas, métodos y aplicaciones*, Madrid: McGRAW-HILL/INTERAMERICANA DE ESPAÑA, S.A.U., 2008.
- [12] R. Cioffi, M. Travaglioni, G. Piscitelli y A. Petrillo, «Artificial Intelligence and Machine Learning Applications in Smart Production: Progress, Trends, and Directions,» *Sustainability*, vol. 12, n° 492, 8 Enero 2020.
- [13] J. Wang, Y. Ma, L. Zhang, R. X. Gao y D. Wu, «Deep learning for smart manufacturing: Methods and applications,» *Journal of Manufacturing Systems*, vol. 48, n° Parte C, pp. 144-156, Julio 2018.
- [14] J. F. Aldana Montse, A. Baldominos Gómez, J. C. García Nieto, F. Mochón Morcillo y I. Navas Delgado, *Introducción al Big Data*, Madrid: García Maroto editores, 2016.
- [15] R. Cioffi, M. Travaglioni, G. Piscitelli y A. Petrillo, «Artificial Intelligence and Machine Learning Applications in Smart Production: Progress, Trends, and Directions,» *Sustainability*, vol. 12, n° 492, 8 Enero 2020.
- [16] J. Wang, Y. Ma, L. Zhang, R. X. Gao y D. Wu, «Deep learning for smart manufacturing: Methods and applications,» *Journal of Manufacturing Systems*, vol. 48, n° Parte C, pp. 144-156, Julio 2018.
- [17] N. Pröllochs y S. Feuerriegel, «Reinforcement Learning in R,» 29 Septiembre 2018. [En línea]. Available: <https://arxiv.org/abs/1810.00240>. [Último acceso: 4 Junio 2020].
- [18] F. Jia, Y. Lei, J. Lin, X. Zhou y L. Na, «Deep neural networks: A promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data,» *Mechanical Systems and Signal Processing*, Vols. %1 de %272-73, pp. 303-315, Mayo 2016.
- [19] J. Huang, Q. Chang y N. Chakraborty, «Machine preventive replacement policy for serial production lines based on reinforcement learning,» de *15th International Conference on Automation Science and Engineering (CASE)*, Vancouver, 2019.
- [20] I. Zajačko, T. Gál, Z. Ságová, V. Mateichyk y D. Wiecek, «Application of artificial intelligence principles in mechanical engineering,» *Innovative Technologies in Engineering Production (ITEP'18)*, vol. 244, Diciembre 2018.