



DOI: <https://doi.org/10.23857/dc.v10i3.4024>

Ciencias Técnicas y Aplicadas
Artículo de Investigación

*Técnicas y aplicaciones de Machine Learning en el campo de la Mecatrónica: Una
Revisión Sistemática de Literatura*

*Machine Learning Techniques and Applications in the Field of Mechatronics: A
Systematic Literature Review*

*Técnicas e aplicações de aprendizagem automática na área da mecatrónica: uma
revisão sistemática da literatura*

Adrián Ramiro Granja Rojas ^I
adrian.granja@unach.edu.ec
<https://orcid.org/0009-0008-9311-8054>

Elba María Boderó Poveda ^{II}
ebodero@unach.edu.ec
<https://orcid.org/0000-0003-3807-5203>

Correspondencia: adrian.granja@unach.edu.ec

***Recibido:** 11 de agosto de 2024 ***Aceptado:** 01 de septiembre de 2024 * **Publicado:** 17 de septiembre de 2024

- I. Ingeniero en Mecatrónica. Maestrante en la Universidad Nacional de Chimborazo. Riobamba-Ecuador.
- II. Doctora en Ciencias Informáticas. Docente e Investigadora del Grupo de Investigación en Telecomunicaciones, Informática, Industria y Construcción en la Universidad Nacional de Chimborazo. Riobamba-Ecuador.

Resumen

A nivel global existe la necesidad de mejorar los procesos industriales. Es por ello que, la combinación de tecnologías de la información, mecánica y electrónica, son pieza fundamental para afrontar desafíos que se presentan en empresas y organizaciones. Este nuevo campo se ha denominado Mecatrónica. Así también, la aplicación de técnicas de Machine Learning (ML) se ha tornado un eje primordial para el análisis de la información tanto a nivel descriptivo como predictivo. El problema radica en que no existe actualmente una visión consolidada y sistematizada a nivel científico sobre las técnicas y aplicaciones específicas de ML en el ámbito de la Mecatrónica. Esta investigación tiene por objetivo identificar cuáles son las técnicas, aplicaciones y desafíos de ML en el campo de la Mecatrónica mediante la revisión sistemática de literatura (SLR), considerando investigaciones y casos de estudio de alto impacto. Para ello se aplicó la metodología PRISMA, y se establece una cadena de búsqueda, con mecanismos sistemáticos de revisión y selección, hasta la obtención de los estudios primarios. Los resultados obtenidos indican que las técnicas de ML más relevantes en el ámbito de la Mecatrónica incluyen Artificial Neural Network (ANN), Convolutional Neural Network (CNN), Recurrent Neural Network (RNN), Support Vector Machine (SVM), K-Nearest Neighbors (KNN) y Decision Trees, aplicadas en tareas como control, detección, automatización, optimización, reconocimiento, diagnóstico, mantenimiento, pronóstico, entre otros. Los principales desafíos son la adaptabilidad e integración con otras tecnologías.

Palabras Claves: Aprendizaje Automático; Mecatrónica; Metodología PRISMA; Procesos Industriales; Revisión Sistemática de Literatura (SLR).

Abstract

At a global level, there is a need to improve industrial processes. For this reason, the combination of information, mechanical and electronic technologies is a fundamental piece to face challenges that arise in companies and organizations. This new field has been called Mechatronics. Likewise, the

application of Machine Learning (ML) techniques has become a fundamental axis for the analysis of information both at a descriptive and predictive level. The problem lies in the fact that there is currently no consolidated and systematized vision at a scientific level on the specific techniques and applications of ML in the field of Mechatronics. This research aims to identify the techniques, applications and challenges of ML in the field of Mechatronics through a systematic literature review (SLR), considering high-impact research and case studies. To do this, the PRISMA methodology was applied, and a search chain was established, with systematic review and selection mechanisms, until obtaining the primary studies. The results obtained indicate that the most relevant ML techniques in the field of Mechatronics include Artificial Neural Network (ANN), Convolutional Neural Network (CNN), Recurrent Neural Network (RNN), Support Vector Machine (SVM), K-Nearest Neighbors (KNN) and Decision Trees, applied in tasks such as control, detection, automation, optimization, recognition, diagnosis, maintenance, prognosis, among others. The main challenges are adaptability and integration with other technologies.

Keywords: Machine Learning; Mechatronics; PRISMA Methodology; Industrial Processes; Systematic Literature Review (SLR).

Resumo

A nível global, há necessidade de melhorar os processos industriais. É por isso que a combinação das tecnologias de informação, mecânicas e eletrónicas é uma peça fundamental para enfrentar os desafios que surgem nas empresas e organizações. Este novo campo foi denominado Mecatrónica. Da mesma forma, a aplicação de técnicas de Machine Learning (ML) tornou-se um eixo fundamental para a análise da informação tanto a nível descritivo como preditivo. O problema é que não existe actualmente uma visão consolidada e sistematizada a nível científico sobre as técnicas e aplicações específicas do ML na área da Mecatrónica. Esta investigação tem como objetivo identificar quais as técnicas, aplicações e desafios do ML no âmbito da Mecatrónica através de uma revisão sistemática da literatura (RSL), considerando pesquisas de alto impacto e estudos de caso. Para tal, aplicou-se a metodologia PRISMA e estabeleceu-se uma cadeia de pesquisa, com mecanismos de revisão e seleção sistemática, até à obtenção dos estudos primários. Os resultados obtidos indicam que as

técnicas de ML mais relevantes na área da Mecatrónica incluem a Rede Neural Artificial (RNA), Rede Neural Convolutiva (CNN), Rede Neural Recorrente (RNN), Máquina de Vetores de Suporte (SVM), K-Vizinhos Mais Próximos (KNN) e Árvores de Decisão, aplicadas em tarefas como controle, detecção, automatização, otimização, reconhecimento, diagnóstico, manutenção, previsão, entre outras. Os principais desafios são a adaptabilidade e a integração com outras tecnologias.

Palavras-chave: Aprendizagem de Máquina; Mecatrónica; Metodologia PRISMA; Processos Industriais; Revisão Sistemática da Literatura (RSL).

Introducción

En las últimas décadas, el campo de la Mecatrónica ha experimentado una transformación significativa gracias a los avances tecnológicos y a la integración de diversas disciplinas como la mecánica, la electrónica y la informática. Esta evolución ha dado lugar al desarrollo de sistemas más inteligentes, eficientes y autónomos. En este contexto, el Machine Learning (ML), una rama de la inteligencia artificial, ha emergido como una herramienta poderosa, ofreciendo soluciones innovadoras y optimizaciones para una amplia gama de aplicaciones en Mecatrónica.

Los procesos industriales se vuelven cada vez más complejos, al evolucionar bajo la influencia de características tecnológicas (Rozo-García, 2020). La Mecatrónica surge como un campo interdisciplinario fundamental para la automatización de empresas que buscan mantener su competitividad (Castro et al., 2022). Esta disciplina integra los principios de la mecánica, la tecnología de la información y la electrónica, actuando de manera conjunta para optimizar los procesos industriales (Abboudi & Belmajdoub, 2021).

En el ámbito de la tecnología de la información, el aprendizaje automático o Machine Learning (ML) se reconoce como una forma de inteligencia artificial en la cual los sistemas no son programados explícitamente, sino que son entrenados mediante el análisis de datos almacenados previamente (Hurwitz & Kirsch, 2018). La incorporación ML en el campo de la Mecatrónica ha conducido a avances significativos en el diseño, control y optimización de sistemas mecatrónicos. Así lo indican también Ayankoso & Olejnik, (2023) junto con Zhang et al., (2019a), la colaboración entre Mecatrónica y ML es crucial para la optimización, control, diagnóstico de fallas y pronóstico. Sin

embargo, a nivel mundial, empresas y organizaciones desconocen el amplio potencial que la inteligencia artificial y las técnicas de ML pueden ofrecer en este ámbito (Sarker et al., 2019a).

A pesar de estos avances, la literatura científica aún carece de una visión consolidada y sistematizada sobre las técnicas y aplicaciones específicas de ML en el ámbito de la Mecatrónica. La ausencia de una perspectiva integral limita la capacidad de investigadores, ingenieros y profesionales para aprovechar plenamente las oportunidades que ofrece esta convergencia tecnológica (Porcelli, 2020). Además, dado que los algoritmos de aprendizaje automático se dividen en diversas categorías, es crucial saber seleccionar el algoritmo más adecuado para el escenario y las características de los datos (Sarker et al., 2019a).

En este contexto, es crucial estudiar las técnicas de aprendizaje automático aplicables en el campo de la Mecatrónica, describir y analizar su funcionamiento, y sintetizar los fundamentos matemáticos subyacentes. De lo contrario, se podría limitar la capacidad de investigadores, ingenieros y profesionales para aprovechar plenamente las oportunidades que ofrece esta convergencia tecnológica. Surge así la pregunta de investigación: ¿Cuáles son las técnicas y aplicaciones de ML en el campo de la Mecatrónica que están documentadas en la literatura científica de alto impacto?

Esta interrogante no solo busca identificar las tecnologías relevantes, sino también establecer un contexto integral que permita comprender el alcance y los desafíos inherentes a la aplicación de ML en entornos mecatrónicos. Responder a esta pregunta no solo ayudará a cerrar las brechas de conocimiento existentes, sino que también sentará las bases para futuros avances y aplicaciones innovadoras en este campo interdisciplinario en constante evolución. Una revisión sistemática de la literatura (SLR) es el camino para identificar estos vacíos, ya que permite abordar las interrogantes surgidas a partir de un problema de investigación, minimizando en gran medida el sesgo y mejorando la calidad en la generación de conocimiento (Bodero et al., 2022).

En la presente investigación, el objetivo fue identificar las técnicas, aplicaciones y desafíos de Machine Learning (ML) en el campo de la Mecatrónica mediante una revisión sistemática de literatura (SLR), considerando investigaciones y casos de estudio de alto impacto. Para lograrlo, se procedió con los siguientes objetivos específicos. Se analizó las técnicas de ML y el sustento matemático que pueden aplicarse en el campo de la Mecatrónica, mediante una SLR, con la finalidad

de establecer un listado de las técnicas más relevantes. Posteriormente, se determinó los desafíos y limitaciones de la aplicación de ML en el campo de la Mecatrónica, mediante un análisis crítico, para el establecimiento de futuras investigaciones en este ámbito. Finalmente, se evaluó el riesgo de sesgo de la SLR, mediante el análisis de la confiabilidad de los resultados para la determinación de la calidad del estudio.

Metodología

Para la realización de la revisión sistemática de literatura (SLR), se utilizó la metodología PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses). Según Page et al. (2021), PRISMA está diseñada principalmente para la revisión sistemática de estudios y es ampliamente aceptada en publicaciones de alto nivel, siendo incluida en numerosas revistas académicas. La aplicación de esta metodología facilita la identificación de fuentes de información y datos relevantes, garantizando la robustez de la investigación a partir de literatura científica sólida y actualizada. En última instancia, la implementación de esta guía se espera que resulte en la publicación de revisiones sistemáticas más transparentes y precisas, lo que a su vez promoverá la toma de decisiones basadas en evidencia.

Dado que se trata de una revisión sistemática de literatura (SLR), se espera recopilar tanto información cuantitativa como cualitativa, el diseño es no experimental y narrativo, respectivamente. Con un corte longitudinal debido a que se analiza estudios científicos de varios años.

El tipo de investigación según el alcance es exploratorio y descriptivo, debido a que busca examinar un tema emergente en la actualidad como lo es la aplicación de técnicas de Machine Learning en el campo de la Mecatrónica, un área que aún no ha sido ampliamente explorado. Además, tiene como objetivo caracterizar las respectivas técnicas, aplicaciones y desafíos, así como sintetizar el sustento matemático que valida su utilización práctica. Para guiar esta investigación, se establecieron las siguientes preguntas de investigación:

- RQ1: ¿Cuáles son las técnicas de ML que pueden aplicarse en el campo de la Mecatrónica y qué sustento matemático tienen las mismas?

- RQ2: ¿Cuáles son los desafíos y limitaciones de la aplicación de ML en el campo de la Mecatrónica?
- RQ3: ¿Cuál es la confianza de los resultados de la SLR?

Fuentes de información y criterio de elegibilidad

Delimitar las fuentes de información y establecer los criterios de elegibilidad es un paso importante en la metodología PRISMA para asegurar la relevancia y calidad de los estudios que se van a incluir en el análisis. Para la investigación en curso, se seleccionó la base de datos SCOPUS como fuente principal, ya que recopila información de estudios de alto impacto publicadas en editoriales científicas de prestigio como como IEEE Xplore, Science Direct, Springer, etc. Esto garantiza la inclusión de una amplia variedad de fuentes académicas relevantes para el tema de investigación.

Una vez identificada la fuente de información, se establecieron los criterios de inclusión y exclusión utilizando parámetros de búsqueda específicos. Estos criterios fueron diseñados para seleccionar estudios que sean relevantes, actuales y directamente relacionados con el tema en cuestión. La formulación de criterios claros y precisos favorece la homogeneidad de la muestra, lo que permite una evaluación minuciosa y consistente de los resultados obtenidos. La población de estudio está compuesta por trabajos de investigación disponibles en los últimos 10 años, totalizando 91 estudios candidatos al 19/06/2024. La muestra final se conforma por los estudios primarios seleccionados después de depurar los manuscritos, aplicando los siguientes términos de inclusión y exclusión:

- Se incluyen trabajos de 10 años a la fecha 2014 a 2023 de la base de datos SCOPUS.
- Se incluyen trabajos en inglés y español.
- Se incluyen únicamente manuscritos de forma de: artículos de revista, artículos de conferencias, revisiones en revista y revisiones en conferencias.
- Se incluyen trabajos que respondan a las preguntas de investigación.
- Se excluyen estudios con erratas, cartas de retracción, o conflictos de interés.

Estrategia de búsqueda

Para identificar estudios relevantes que exploren la aplicación de técnicas de Machine Learning en el campo de la Mecatrónica, se utilizó una estrategia de búsqueda que se centró en los términos clave "MECHATRONIC" y "MACHINE LEARNING", debido a que es el tema principal de la presente

investigación. La cadena de búsqueda fue la siguiente, en ella se consideró la búsqueda por título, abstract y palabras clave:

```
( TITLE-ABS-KEY ( "mechatronic" ) AND TITLE-ABS-KEY ( "machine learning" ) ) AND  
PUBYEAR > 2013 AND PUBYEAR < 2024 AND ( LIMIT-TO ( DOCTYPE , "ar" ) OR LIMIT-TO  
( DOCTYPE , "cp" ) OR LIMIT-TO ( DOCTYPE , "cr" ) OR LIMIT-TO ( DOCTYPE , "re" ) ) AND  
( LIMIT-TO ( LANGUAGE , "English" ) )
```

Esta cadena de búsqueda se complementó con límites temporales, restringiendo los resultados a artículos publicados entre 2014 y 2023. Además, se aplicaron filtros para incluir únicamente documentos de tipo artículo de investigación, conferencias, revisiones y otros formatos pertinentes. También se establecieron criterios adicionales para optimizar la búsqueda, como el idioma, limitando los resultados a aquellos publicados en inglés.

Proceso de selección de estudios

Una vez completada la búsqueda inicial de los estudios, se identificaron un total de 91 registros. Durante la primera revisión, se analizó los estudios candidatos. Este proceso implicó una exploración detallada para eliminar aquellos que no cumplían con los criterios de inclusión. Se excluyeron estudios duplicados y actas de conferencia con múltiples documentos, debido a que no es factible revisar el gran número de estudios indexados en dichas actas. Además, se verificó la relevancia de los estudios en relación con las técnicas de ML y su aplicación en el campo de la Mecatrónica. Como resultado, 77 estudios fueron seleccionados para una revisión más profunda.

En una segunda selección, los estudios fueron revisados y analizados en sus títulos, resúmenes y palabras clave, asegurando que los estudios seleccionados respondieran a las preguntas de investigación y tengan enfoque al ML en la Mecatrónica. Esta fase permitió refinar la lista de estudios a aquellos más pertinentes y de mayor calidad. Al final de esta etapa, se seleccionaron 70 estudios para una recuperación a texto completo.

La recuperación de estudios a texto completo consistió en la búsqueda y descarga de los 70 estudios seleccionados. Este tratamiento es importante para asegurar que toda la información relevante y necesaria para el análisis esté disponible para ser evaluada en su totalidad, permitiendo una

comprensión completa de cada estudio. De los estudios seleccionados para la recuperación, 67 fueron encontrados y descargados.

Proceso de extracción de los datos

El análisis a texto completo y la extracción de características se llevó a cabo para responder a las preguntas de investigación establecidas. Este proceso incluyó la identificación de las técnicas de ML utilizadas, sus aplicaciones en la Mecatrónica y el sustento matemático detrás de cada técnica. Se utilizó un enfoque sistemático para extraer datos cuantitativos y cualitativos que proporcionarán una visión integral y detallada de cada estudio.

En la Figura 1 se muestra el diagrama propuesto por la metodología PRISMA, que detalla el proceso realizado y el número de estudios resultantes en cada etapa.

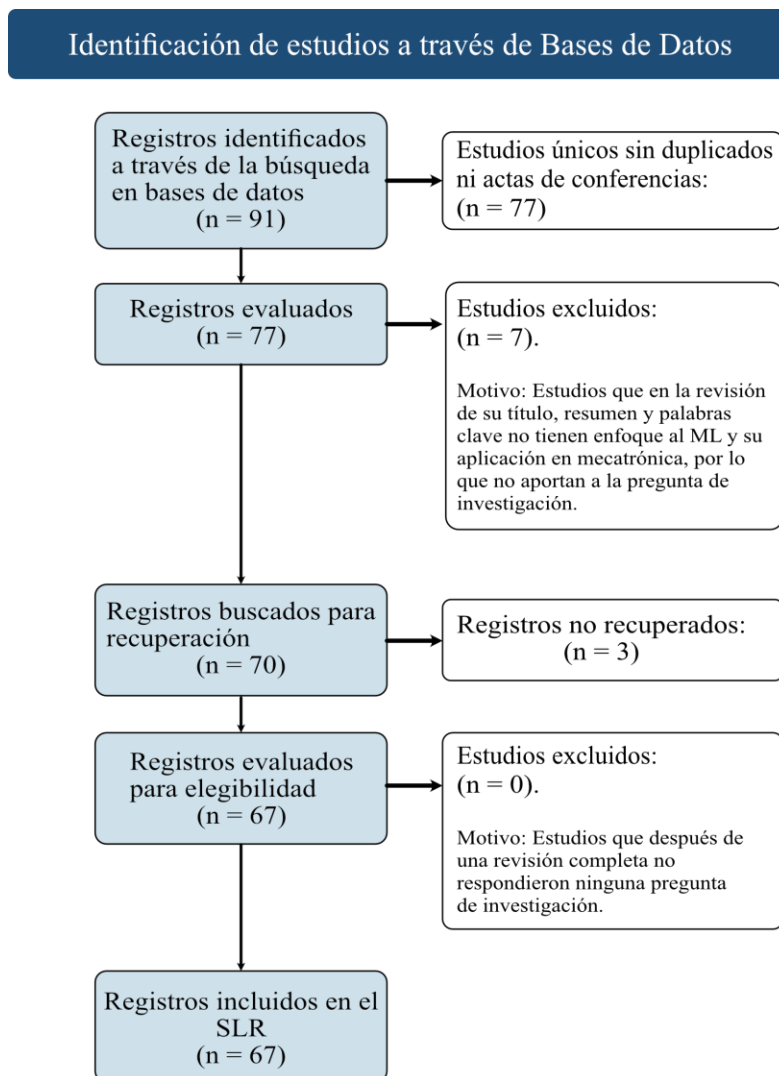


Figura 1. Proceso de selección de estudios aplicando la metodología PRISMA

Se consideraron factores como la metodología de los estudios, la calidad de los datos y posibles conflictos de interés para asegurar la confiabilidad de los resultados de la revisión sistemática de literatura. En la Tabla 1 se presenta los porcentajes correspondientes al total de estudios en cada etapa del proceso.

Tabla 1. Estudios por etapa

Estudios	Total	Porcentaje	Descripción
Candidatos	91	100%	Estudios resultantes de la aplicación de la cadena de búsqueda
Candidatos depurados	77	78%	Estudios únicos sin duplicados ni actas de conferencia.
Seleccionados	70	76.9%	Estudios seleccionados luego de la revisión de título, resumen, palabras clave
Recuperados	67	73.6%	Estudios descargados a texto completo
Finales	67	73.6%	Estudios revisados a texto completo y seleccionados

Durante el proceso de selección de estudios, los 70 estudios seleccionados cumplieron con los criterios de inclusión definidos, pero 3 fueron descartados debido a que no se pudieron recuperar a texto completo para su análisis, estos son: A Mechatronic Engineering Approach on the Design of a Telemetry, Tracking, and Command System for Monitoring of a 3U CubeSat Nanosatellite (Monroy & Barrera, 2022), Defence base operated mecanum wheel robot using night vision camera (Krishna & Khan, 2020) y Feature extraction and analysis from a biomimetic tactile sensor (Ku et al., 2014).

Métodos de síntesis

Se realizó un meta-análisis, la información se organiza en tablas y figuras para ofrecer al lector una visión más clara sobre las técnicas de ML y las distintas aplicaciones en Mecatrónica, los desafíos que se deben superar, y las limitaciones existentes en este campo de estudio.

Resultados

La Figura 2 muestra la distribución de estudios por año, con el porcentaje equivalente y el número de estudios correspondiente. Se observa un aumento significativo en el número de estudios publicados en los años más recientes, particularmente en 2023. Esta tendencia sugiere un creciente interés y

actividad en el área de investigación en cuestión, reflejado en el notable incremento de estudios en el último año del análisis.




Figura 2. Registros encontrados por año

La Figura 3 ilustra la distribución de los estudios según la fuente de la cual fueron obtenidos, junto con su porcentaje respecto al total, la mayor parte de los estudios provienen de ScienceDirect e IEEE Xplore.




Figura 3. Registros según las editoriales indexadas en Scopus

La Figura 4 muestra la clasificación de los estudios según el tipo de documento, proporcionando una visión clara de la proporción entre artículos científicos, documentos de conferencia y artículos de revisión. Esta distribución refleja la diversidad de fuentes y tipo de publicaciones utilizadas en la investigación.

Técnicas y aplicaciones de Machine Learning en el campo de la Mecatrónica: Una Revisión Sistemática de Literatura




Figura 4. Registros obtenidos por tipo de publicación

RQ1: ¿Cuáles son las técnicas de ML que pueden aplicarse en el campo de la Mecatrónica y qué sustento matemático tienen las mismas?

La Tabla 2 muestra las técnicas de ML que se utilizan con mayor frecuencia en el campo de la Mecatrónica, destacando las redes neuronales como Artificial Neural Network (ANN), Convolutional Neural Network (CNN) y Recurrent Neural Network (RNN), además de Support Vector Machine entre otros. Se detallan también las aplicaciones específicas de estos algoritmos en el campo de la Mecatrónica, proporcionando información crucial para comprender cómo puede ser implementado y optimizado cada enfoque en el desarrollo de sistemas mecatrónicos inteligentes.

Tabla 2. Aplicación de las técnicas de ML en la Mecatrónica

Técnica de ML	de Aplicación en Mecatrónica	Algoritmos empleados	Registros	Porcentaje
Artificial Neural Network (ANN)	Diagnóstico y mantenimiento. Control de sistemas. Detección de fallas. Modelado y control de robots.	Es muy común, en las redes neuronales, el uso de algoritmos de retropropagación, funciones de activación o funciones de pérdida. El algoritmo de retropropagación, según Larranaga et al. (1997), se puede representar como: $h_i(x_i, \dots, x_n, w_{i_1}, \dots, w_{i_n}) = \sum_{j=1}^n w_{ij} x_j - \theta_i$	16	23.88 %

Técnicas y aplicaciones de Machine Learning en el campo de la Mecatrónica: Una Revisión Sistemática de
Literatura

Convolutional Neural Network (CNN)	Reconocimiento de patrones.	La función de activación, que representa simultáneamente la salida de la neurona y su estado de activación, se denota por:	12	17.91 %
	Procesamiento de imágenes.			
	Detección de objetos y clasificación de imágenes	$y_i = f_i(h_i) = f_i\left(\sum_{j=0}^n w_{ij} x_j\right)$		
Recurrent Neural Network (RNN)	Predicción y control de sistemas dinámicos.	La mayoría de los modelos de redes neuronales utilizan el método basado en gradientes (Ayankoso & Olejnik, 2023) para minimizar la pérdida J de la red:	6	8.96 %
	Mantenimiento predictivo.	$J = MSE(y, \hat{y}) = \frac{1}{m} \sum_j^m (y_j - \hat{y}_j)^2$		
	Modelado y control de robots con dependencia temporal.	Donde J es la pérdida entre la salida objetivo y la salida de red prevista, y es la salida objetivo, \hat{y} es la salida predicha de la red y m representa el número de puntos de datos.		
Support Vector Machine (SVM)	Clasificación de señales.	Los SVM suelen hacer uso de los algoritmos de Activación (Rúa et al., 2012). Dado un conjunto donde	11	16.42 %
	Control de calidad en procesos.	existe al menos un hiperplano que separa dos conjuntos de la forma:		
	Detección y clasificación de objetos	$w \cdot x + b = 0$		
Decision Tree	Clasificación de fallos.	El problema de activación de SVM puede describirse como:	9	13.43 %
	Toma de decisiones.	$\min_{w \in \mathbb{R}^{d_2}} \ w\ ^2$		
	Mantenimiento predictivo.	La ganancia de información Chanmee & Kesorn (2023) es una medida basada en la impureza que utiliza la entropía para identificar la impureza de cada atributo, el atributo que tiene la mayor ganancia de información se utiliza como nodo. La entropía de los datos de entrenamiento se puede expresar como:		

Técnicas y aplicaciones de Machine Learning en el campo de la Mecatrónica: Una Revisión Sistemática de Literatura

	Control de procesos.	$Info(D) = - \sum_{i=1}^m p_i \log_2(p_i) \quad (6)$		
	Optimización de sistemas.	<p>Donde $Info(D)$ es la entropía del conjunto de datos D, que tiene m valores distintos, y p_i es la probabilidad de que una instancia pertenezca a la clase i.</p>		
	Diagnóstico y mantenimiento.	<p>La distancia euclidiana (Saadatfar et al., 2020) se utiliza en KNN para encontrar los vecinos más cercanos de un punto dado en el espacio de características, se representa como:</p>		
K-Nearest Neighbor (KNN)	Detección de anomalías.	$d_j^i = \max \left(\sqrt{p_j^2 - (C_j^i)^2} \right) \forall P \in c_i$	5	7.46 %
	Reconocimiento de patrones	<p>Donde d_j^i es la distancia euclidiana máxima entre dos puntos de datos del i^{th} cumulo y su centro (C^i) a lo largo del eje j^{th}</p>		
	Diagnóstico y mantenimiento preventivo	<p>Random Forest construye diferentes conjuntos de entrenamiento para aumentar la diferencia entre los modelos de clasificación (Yuan et al., 2020). A través de k rondas de entrenamiento, se obtiene una secuencia de modelos de clasificación:</p>		
Random Forest	Clasificación y regresión de datos.	$\{h_1(X), h_2(X), \dots, h_K(X)\}$ <p>Que luego es usado para formar un sistema modelo de clasificación. El resultado final de la clasificación del sistema adopta el método de votación por mayoría simple. La decisión final de clasificación es:</p>	4	5.97 %
	Control y Automatización	<p>Mediante parámetros estadísticos, se calcula el rendimiento de la red neuronal. Es común la aplicación del Error Cuadrático Medio (Ec. 10), el Error Absoluto</p>		
tuned-Residual Iteration Decomposition (t-RIDE)	Mejora de modelos predictivos en tiempo real	<p>Medio (Ec. 11), el Error Cuadrático Medio (Ec. 12) y el coeficiente de determinación R^2 (Erkaymaz, 2020):</p>	4	5.97 %

Feed-Forward Neural Network (FFNN)	Ajuste de modelos	$MSE = \frac{1}{N} \sum_{j=1}^N (y_j - d_j)^2$			(10)
	Modelado y control de sistemas	$MAE = \frac{1}{N} \sum_{j=1}^N y_j - d_j $			(11)
	Reconocimiento de patrones	$RMSE = \sqrt{\frac{1}{N} \sum_{j=1}^N (y_j - d_j)^2}$	3	4.48%	(12)
	Predicción de series temporales	$R^2 = 1 - \frac{\sum_{j=1}^N (y_j - d_j)^2}{\sum_{j=1}^N d_j^2}$			(13)

En el proceso, también se identificaron técnicas de ML que se mencionan con menor frecuencia en las investigaciones, entre ellas, tenemos Extreme Learning Machine (Zaitceva & Andrievsky, 2022; Zhang et al., 2016b), Gradient Boosting Decision Trees (GBDT) (Skvorchevsky, 2023; Zhang et al., 2020c), Gradient Boosting Machines (GBM) (Zaitceva & Andrievsky, 2022) y Linear Discriminant Analysis (LDA) (Aume et al., 2023; Zamudio-Ramirez et al., 2021) que se utiliza para la reducción de dimensionalidad y clasificación. Varias técnicas de regresión como Linear Regression (Buranich et al., 2020; Gerschütz et al., 2023), Logistic Regressions (Chidhananda & Kulkarni, 2021), Polynomial Regression (Gerschütz et al., 2023) y Regression Tree (Oleaga et al., 2018) que permiten la predicción de fallos y el análisis de rendimiento en los componentes.

También se incluyeron métodos avanzados para el control, la predicción y el diagnóstico, como el aprendizaje por refuerzo (Reinforcement Learning) (Martinez et al., 2015; Nocentini et al., 2022) y sus variantes como A2C (Advantage Actor-Critic) (Manzl et al., 2023), Energy-balancing Actor-critic (EBAC) (Nagesh Rao et al., 2014) y PPO (Proximal Policy Optimization) (Manzl et al., 2023), así como el uso de redes neuronales profundas como Residual Neural Networks (ResNet) (Caceres-Castellanos et al., 2023; Kim et al., 2023), Long Short-Term Memory (LSTM) (Ayankoso & Olejnik, 2023), Deep Q-Network (DQN) (Manzl et al., 2023) y el método basado en políticas como PGPE (Policy Gradient with Parameter-based Exploration) (Van et al., 2014).

En el campo de la optimización, se destacó el uso de algoritmos como el ABC (Artificial Bee Colony) (Huang & Chuang, 2020) y el FPA (Flower Pollination Algorithm) (Huang & Xu, 2020). También

se mencionaron métodos probabilísticos como el Hidden Markov Models (HMM) (Ambadekar et al., 2023) y Gaussian Processes (GPs) (Poot et al., 2022), así como técnicas para la reducción de dimensionalidad como el DPCA (Dynamic Principal Component Analysis) (Zhang et al., 2020c). La integración de técnicas emergentes como el aprendizaje de transferencia (Transfer Learning) (Thielen et al., 2023) y las redes de aprendizaje automático no paramétricas como el GPR (Gaussian Process Regression) (Homburger et al., 2023) también forman parte, subrayando así la diversidad y el potencial innovador de las técnicas de ML en el ámbito de la Mecatrónica.

RQ2: ¿Cuáles son los desafíos y limitaciones de la aplicación de ML en el campo de la Mecatrónica?

La aplicación de técnicas de Machine Learning (ML) en el campo de la Mecatrónica presenta una serie de desafíos que deben ser abordados cuidadosamente para garantizar resultados exitosos. Entre los principales se destacan la capacidad de adaptar diseños creados para un dominio a otros entornos debido a que los modelos entrenados en condiciones específicas pueden tener dificultades para generalizar a situaciones no vistas durante el entrenamiento. La evaluación y validación de técnicas de ML existentes, un análisis de escalabilidad para actuales sistemas o mejoras futuras y la optimización de los algoritmos aplicados para asegurar la eficiencia de los sistemas son tareas pendientes. La Figura 5 muestra la representatividad de los enfoques y áreas de investigación junto con el número de investigaciones que lo mencionan. Estas prioridades reflejan las tendencias actuales y los desafíos del ML en el campo de la Mecatrónica.

Técnicas y aplicaciones de Machine Learning en el campo de la Mecatrónica: Una Revisión Sistemática de Literatura




Figura 5. Desafíos de la implementación de las técnicas de ML en la Mecatrónica

Si bien las técnicas de Machine Learning (ML) ofrecen un gran potencial para mejorar el rendimiento y la eficiencia de los sistemas mecatrónicos, también existen limitaciones inherentes a su aplicación en este campo. Una de las principales restricciones es la necesidad de grandes conjuntos de datos de alta calidad para entrenar modelos precisos, lo cual puede ser un desafío en entornos industriales donde los datos suelen ser escasos, ruidosos o incompletos. Además, la complejidad computacional de ciertos algoritmos de ML puede dificultar su implementación en tiempo real, especialmente en sistemas embebidos con recursos limitados.

Otro factor limitante es que muchas soluciones se centran en campos o dominios específicos, lo que su implementación a otros entornos es un tema nuevo de investigación. Asimismo, la integración de soluciones basadas en ML con sistemas mecatrónicos existentes puede requerir esfuerzos significativos de adaptación y personalización. La Figura 6 muestra las principales limitaciones del ML aplicada al campo de la Mecatrónica y el número de estudios que lo mencionan. Estas limitaciones destacan las barreras y desafíos críticos que enfrentan los sistemas mecatrónicos al incorporar tecnologías de ML.

Técnicas y aplicaciones de Machine Learning en el campo de la Mecatrónica: Una Revisión Sistemática de Literatura

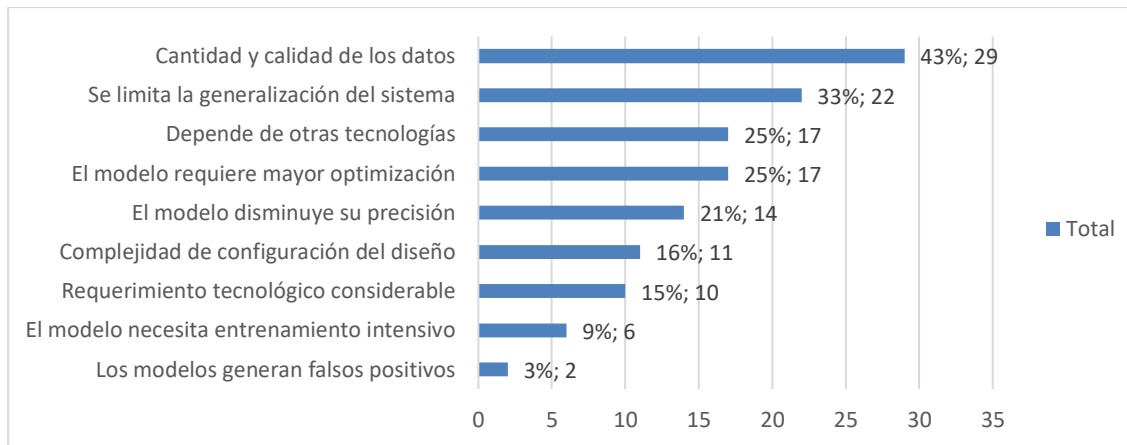


Figura 6. Limitaciones de las técnicas de ML en la Mecatrónica

RQ3: ¿Cuál es la confianza de los resultados de la SLR?

Para evaluar la confianza de los resultados obtenidos en la Revisión Sistemática de Literatura, se llevó a cabo un análisis cuantitativo de los estudios que respondieron a cada pregunta de investigación. En las Tablas 3 y 4 se presenta este análisis, donde se indica el número de estudios que abordaron cada pregunta específica. A partir de estos datos, se calculó el porcentaje de confianza correspondiente a cada respuesta o categoría en relación con el total de estudios que trataron esa pregunta. Con estos porcentajes, se establecieron medidas estadísticas como el porcentaje mínimo, máximo, la media, la mediana, el rango y la amplitud. Estos parámetros permiten clasificar las respuestas en términos de su confiabilidad, distinguiendo entre alta, media y baja confianza.

Este enfoque proporciona un criterio objetivo para evaluar la representatividad y solidez de los resultados de la SLR. Al considerar la cantidad de estudios que respaldan cada hallazgo, se puede tener una mejor comprensión de la confianza que se puede depositar en las respuestas a las preguntas de investigación planteada.

Tabla 3. Calidad de respuestas a las preguntas de investigación

Pregunta	NE	VMin VMax	R, A	Media	Median a	Nota.
RQ1: ¿Cuáles son las técnicas de ML que pueden aplicarse en el campo de la Mecatrónica y qué sustento matemático tienen las mismas?	60	1% - 27%	R=26% A=9%	4%	2%	NE:
RQ2: ¿Cuáles son los desafíos y limitaciones de la aplicación de ML en el campo de la Mecatrónica?	67	2% - 53%	R=51% A=17%	18%	17%	

Pregunta	Confianza baja			Confianza media			Confianza alta		
	LI	LS	N (%)	LI	LS	N (%)	LI	LS	N (%)
RQ1: ¿Cuáles son las técnicas de ML que pueden aplicarse en el campo de la Mecatrónica y qué sustento matemático tienen las mismas?	1%	10%	42 (90%)	10%	19%	3 (6%)	19%	27%	2 (4%)
RQ2: ¿Cuáles son los desafíos y limitaciones de la aplicación de ML en el campo de la Mecatrónica?	2%	19%	7 (39%)	19%	36%	6 (33%)	36%	53%	5 (28%)

Número Estudio, VMin = Valor mínimo, VMax = Valor máximo, A = Amplitud

Nota. R = Rango, LI = Límite inferior, LS = Límite superior, N = Número y porcentaje de resultados que proporcionan confianza media, alta y baja. La RQ3 no se menciona debido a que se refiere a la confianza de los resultados de SLR.

Discusión

En base a los resultados de la SLR, la integración de técnicas de ML en la Mecatrónica ha demostrado ser un factor crucial para la evolución y optimización de sistemas complejos. A través de esta revisión, se ha identificado que técnicas como Artificial Neural Networks (ANN), Convolutional Neural Networks (CNN), Recurrent Neural Network (RNN), Support Vector Machine (SVM), K-Nearest Neighbors (KNN) y Decision Trees son aplicadas frecuentemente en diversas tareas de la Mecatrónica, incluyendo el control, optimización, diagnóstico y mantenimiento de sistemas. Estas técnicas permiten a los sistemas mecatrónicos ser más inteligentes y autónomos, incrementando su eficiencia y capacidad de respuesta ante diversas situaciones industriales.

Estos hallazgos son coherentes con estudios previos como el de Zhang et al. (2019a), que destaca la efectividad de ANN, CNN y SVM para el mantenimiento predictivo y el diagnóstico de fallas en sistemas industriales. De igual manera, la revisión de Ayankoso & Olejnik (2023), resalta la importancia de dichas técnicas incluyendo Feedforward Neural Network (FNN) y Long Short-term Memory (LSTM), subrayando su aplicación para el modelado y el control de sistemas electrónicos dinámicos con alta precisión. Además, se enfatiza la aplicación de técnicas como Decision Trees y Random Forest para problemas de clasificación, proporcionando mayor precisión y robustez en la clasificación (Bey-Temsamani et al., 2020; Caceres-Castellanos et al., 2023; Oleaga et al., 2018)

Sin embargo, la implementación de técnicas de Machine Learning (ML) en el campo de la Mecatrónica presenta varios desafíos significativos. Uno de los principales obstáculos es la necesidad de grandes volúmenes de datos de alta calidad para entrenar los modelos de ML, algo que frecuentemente no está disponible en entornos industriales (Nocentini et al., 2022). Además, la integración de ML con tecnologías existentes puede ser compleja debido a la heterogeneidad de los sistemas y a la falta de estándares comunes (Porcelli, 2020). La adaptabilidad de estos modelos a diferentes condiciones operativas y su capacidad de generalización son aspectos críticos que deben ser abordados para maximizar el potencial de estas tecnologías en aplicaciones Mecatrónicas (Sarker et al., 2019b).

En la práctica, las técnicas de ML pueden ser adoptadas para mejorar la eficiencia y la capacidad de respuesta de los sistemas mecatrónicos. Pero, a pesar de los continuos avances, el etiquetado industrial

automático y menos costoso es una limitante para el entrenamiento de los modelos. La operación de etiquetado de los datos, aunque se trate de conjuntos pequeños, es claramente costosa (Bey-Temsamani et al., 2020) y los algoritmos de aprendizaje automático dependen estrechamente de la calidad de la información (Chidhananda & Kulkarni, 2021). Desde el punto de vista investigativo, frecuentemente faltan datos fiables y realistas. Esta situación pone en evidencia la necesidad de una mayor colaboración de la industria (Gerschütz et al., 2023).

Por lo tanto, se destaca la importancia de optimizar y mejorar las técnicas de ML para perfeccionar los sistemas mecatrónicos. Analizar, visualizar y tratar los datos recopilados además de entender las matemáticas detrás de los algoritmos ayuda a la selección adecuada de la técnica y a la precisión de la misma (Ambadekar et al., 2023). El desarrollo de enfoques híbridos para aprovechar mejor las fortalezas es una posible solución a futuro (Zhang et al., 2020c). Además, investigar el uso de ML para la adaptación en tiempo real y el aprendizaje continuo en sistemas mecatrónicos podría mejorar su flexibilidad y robustez. Con el crecimiento de la Industria 4.0 y el Internet de las Cosas (IoT), se prevé que las colaboraciones interdisciplinarias entre expertos en Mecatrónica, inteligencia artificial y ciencias de datos jueguen un papel crucial en el desarrollo de soluciones innovadoras y sostenibles (Ambadekar et al., 2023; Rozo-García, 2020).

El proceso de revisión también presenta limitaciones. Aunque se utilizó la metodología PRISMA para asegurar una selección rigurosa y sistemática de los estudios, es posible que algunos estudios relevantes no hayan sido incluidos debido a restricciones de idioma o accesibilidad. Además, la revisión se centró en bases de datos de alta visibilidad como Scopus, lo que puede haber excluido investigaciones relevantes publicadas en otras fuentes menos prominentes.

Conclusiones

En el campo de la Mecatrónica, el uso de técnicas de Machine Learning (ML) está en constante expansión, ofreciendo mejoras significativas en el control, diagnóstico y optimización de sistemas complejos. Entre las técnicas más destacadas, las Artificial Neural Networks (ANN), Convolutional Neural Networks (CNN) y Support Vector Machines (SVM) son frecuentemente aplicadas. Estas técnicas se utilizan para una variedad de tareas, como modelado y control de sistemas, control de

calidad, detección y clasificación de objetos, detección de fallas, reconocimiento de patrones y procesamiento de imágenes.

Por otro lado, la aplicación de ML en la Mecatrónica presenta varios desafíos y limitaciones que deben ser abordados para maximizar su potencial. Dado que muchas de las técnicas dependen en gran medida de los datos, es necesario visualizar y evaluar los datos recopilados junto al sustento matemático detrás del algoritmo utilizado. La validación experimental exhaustiva en una variedad de entornos y condiciones para valorar la robustez y generalizar los sistemas abre la posibilidad de extender aplicaciones específicas de un dominio hacia otros para el diseño de sistemas mecatrónicos complejos. Se hace un enfoque especial a la cantidad y calidad de los datos, pues la adquisición simplificada y la seguridad de los datos en el contexto real de desarrollo es una necesidad.

Es muy común la integración de ML y la Mecatrónica en varios aspectos, pero desde el punto de vista investigativo, a menudo faltan datos fiables y realistas. Esto pone en evidencia la necesidad de una mayor colaboración en la industria. Se sugiere la necesidad de investigar y desarrollar nuevos enfoques que integren de manera más completa y sistemática la observación, el aprendizaje, la toma de decisiones y la ejecución en sistemas mecánicos adaptativos lo que puede dar como resultado una industria más eficiente y sostenible

Referencias

- Abboudi, A., & Belmajdoub, F. (2021). Hybrid Diagnosis Method Applied to Switched Mechatronic Systems. *Journal Européen des Systèmes Automatisés*, 54, 683-691. <https://doi.org/10.18280/jesa.540503>
- Ambadekar, P., Ambadekar, S., Choudhari, C., Patil, S., & Gawande, S. (2023). Artificial intelligence and its relevance in mechanical engineering from Industry 4.0 perspective. *Australian Journal of Mechanical Engineering*, 1-21. <https://doi.org/10.1080/14484846.2023.2249144>
- Aume, C., Pal, S., Jolfaei, A., & Mukhopadhyay, S. (2023). Multimodal Social Data Analytics on the Design and Implementation of an EEG-Mechatronic System Interface. *Journal of Data and Information Quality*, 15. <https://doi.org/10.1145/3597306>

- Ayankoso, S., & Olejnik, P. (2023). Time-Series Machine Learning Techniques for Modeling and Identification of Mechatronic Systems with Friction: A Review and Real Application. *Electronics*, 12(17), Article 17. <https://doi.org/10.3390/electronics12173669>
- Bey-Temsamani, A., Ompusunggu, A., & Hammer, F. (2020). AI meets Agriculture: A Smart System for Foreign Object Damage Avoidance. *2020 IEEE Conference on Industrial Cyberphysical Systems (ICPS)*, 1, 191-195. <https://doi.org/10.1109/ICPS48405.2020.9274735>
- Bodero, E., De Giusti, M., Morales, C., Bodero, E., De Giusti, M., & Morales, C. (2022). Preservación digital a largo plazo: Estándares, auditoría, madurez y planificación estratégica. *Revista Interamericana de Bibliotecología*, 45(2). <https://doi.org/10.17533/udea.rib.v45n2e344178>
- Buranich, V., Rogoz, V., Postolnyi, B., & Pogrebnyak, A. (2020). Predicting the Properties of the Refractory High-Entropy Alloys for Additive Manufacturing-Based Fabrication and Mechatronic Applications. *2020 IEEE 10th International Conference Nanomaterials: Applications & Properties (NAP)*, 1-5. <https://doi.org/10.1109/NAP51477.2020.9309720>
- Caceres-Castellanos, C., Fehsenfeld, M., & Kortmann, K.-P. (2023). Condition Monitoring using Domain-Adversarial Networks with Convolutional Kernel Features. *IFAC-PapersOnLine*, 56(2), 7746-7752. <https://doi.org/10.1016/j.ifacol.2023.10.1180>
- Castro, B., Parrales, K., Ferrín, J., & García, J. (2022). La Mecatrónica y su importancia en la sociedad. *Journal TechInnovation*, 1(1), Article 1. <https://doi.org/10.47230/Journal.TechInnovation.v1.n1.2022.46-54>
- Chanmee, S., & Kesorn, K. (2023). Semantic decision Trees: A new learning system for the ID3-Based algorithm using a knowledge base. *Advanced Engineering Informatics*, 58, 102156. <https://doi.org/10.1016/j.aei.2023.102156>
- Chidhananda, R., & Kulkarni, A. (2021). Application of automation strategies to prevent failure in mechatronic water plant system. *Materials Today: Proceedings*, 37, 1480-1485. <https://doi.org/10.1016/j.matpr.2020.07.105>
- Erkaymaz, O. (2020). Resilient back-propagation approach in small-world feed-forward neural network topology based on Newman–Watts algorithm. *Neural Computing and Applications*, 32(20), 16279-16289. <https://doi.org/10.1007/s00521-020-05161-6>

- Gerschütz, B., Sauer, C., Kormann, A., Nicklas, S., Goetz, S., Roppel, M., Tremmel, S., Paetzold-Byhain, K., & Wartzack, S. (2023). Digital Engineering Methods in Practical Use during Mechatronic Design Processes. *Designs*, 7(4), Article 4. <https://doi.org/10.3390/designs7040093>
- Homburger, H., Wirtensohn, S., Diehl, M., & Reuter, J. (2023). Comparison of Data-Driven Modeling and Identification Approaches for a Self-Balancing Vehicle. *IFAC-PapersOnLine*, 56(2), 6839-6844. <https://doi.org/10.1016/j.ifacol.2023.10.611>
- Huang, H.-C., & Chuang, C.-C. (2020). Artificial Bee Colony Optimization Algorithm Incorporated With Fuzzy Theory for Real-Time Machine Learning Control of Articulated Robotic Manipulators. *IEEE Access*, 8, 192481-192492. <https://doi.org/10.1109/ACCESS.2020.3032715>
- Huang, H.-C., & Xu, J.-J. (2020). Evolutionary Machine Learning for Optimal Polar-Space Fuzzy Control of Cyber-Physical Mecanum Vehicles. *Electronics*, 9(11), Article 11. <https://doi.org/10.3390/electronics9111945>
- Hurwitz, J., & Kirsch, D. (2018). *Machine Learning For Dummies*, IBM Limited Edition.
- Kim, D., TabkhPaz, M., Park, S. S., & Lee, J. (2023). Development of a vision-based automated hole assembly system with quality inspection. *Manufacturing Letters*, 35, 64-73. <https://doi.org/10.1016/j.mfglet.2023.08.018>
- Krishna, R., & Khan, S. (2020). Defence Base Operated Mecanum Wheel Robot Using Night Vision Camera. *Journal of Advanced Research in Dynamic and Control Systems*, 12(6), 443-449. <https://doi.org/10.5373/JARDCS/V12I6/S20201048>
- Ku, H.-C., Liu, Y.-C., Su, J.-Y., & Kung, C.-C. (2014). Feature Extraction and Analysis from a Biomimetic Tactile Sensor. *中國機械工程學刊*, 35(4), 313-319. <https://www.airitilibrary.com/Article/Detail/02579731-201408-201501210010-201501210010-313-319>
- Larranaga, P., Inza, I., & Moujahid, A. (1997). Tema 8. Redes Neuronales. *Redes Neuronales, U. del P. Vasco*, 12, 17. <http://www.sc.ehu.es/ccwbayes/docencia/mmcc/docs/t8neuronales>

- Manzl, P., Rogov, O., Gerstmayr, J., Mikkola, A., & Orzechowski, G. (2023). Reliability evaluation of reinforcement learning methods for mechanical systems with increasing complexity. *Multibody System Dynamics*, 1-25. <https://doi.org/10.1007/s11044-023-09960-2>
- Martinez, C., Schoenmakers, F., Naus, G., Meessen, K., Douven, Y., Loo, H., Bruijnen, D., Aangenent, W., Groenen, J., Ninhuijs, B., Briegel, M., Hoogendijk, R., Brakel, P., Berg, R., Hendriks, O., Arts, R., Botden, F., Houtman, W., Klooster, M., & Molengraft, M. (2015). Tech United Eindhoven, winner RoboCup 2014 MSL: Middle Size League. 8992, 60-69. <https://doi.org/10.1007/978-3-319-18615-3-5>
- Monroy, I., & Barrera, F. (2022). A Mechatronic Engineering Approach on the Design of a Telemetry, Tracking, and Command System for the Monitoring of a 3u Cubesat Nanosatellite. *International Astronautical Federation*. <https://iafastro.directory/iaac/archive/browse/IAC-22/B2/IPB/72264/>
- Nagesh Rao, S., Lopes, G., Jeltsema, D., & Babuška, R. (2014). Passivity-based reinforcement learning control of a 2-DOF manipulator arm. *Mechatronics*, 24(8), 1001-1007. <https://doi.org/10.1016/j.mechatronics.2014.10.005>
- Nocentini, O., Kim, J., Bashir, Z., & Cavallo, F. (2022). Learning-based control approaches for service robots on cloth manipulation and dressing assistance: A comprehensive review. *Journal of NeuroEngineering and Rehabilitation*, 19. <https://doi.org/10.1186/s12984-022-01078-4>
- Oleaga, I., Pardo, C., Zulaika, J., & Bustillo, A. (2018). A machine-learning based solution for chatter prediction in heavy-duty milling machines. *Measurement*, 128, 34-44. <https://doi.org/10.1016/j.measurement.2018.06.028>
- Page, M., McKenzie, J., Bossuyt, P., Boutron, I., Hoffmann, T., Mulrow, C., Shamseer, L., Tetzlaff, J., Akl, E., Brennan, S., Chou, R., Glanville, J., Grimshaw, J., Hróbjartsson, A., Lalu, M., Li, T., Loder, E., Mayo-Wilson, E., McDonald, S.,... & Alonso-Fernández, S. (2021). Declaración PRISMA 2020: Una guía actualizada para la publicación de revisiones sistemáticas. *Revista Española de Cardiología*, 74(9), 790-799. <https://doi.org/10.1016/j.recesp.2021.06.016>

- Poot, M., Portegies, J., Mooren, N., van Haren, M., van Meer, M., & Oomen, T. (2022). Gaussian Processes for Advanced Motion Control. In 2022 American Control Conference (ACC), 3355-3355. <https://doi.org/10.23919/ACC53348.2022.9867420>
- Porcelli, A. (2020). La inteligencia artificial y la robótica: Sus dilemas sociales, éticos y jurídicos. *Derecho global. Estudios sobre derecho y justicia*, 6(16), 49-105. <https://doi.org/10.32870/dgedj.v6i16.286>
- Rozo-García, F. (2020). Revisión de las tecnologías presentes en la industria 4.0. *Revista UIS Ingenierías*, 19(2), Article 2. <https://doi.org/10.18273/revuin.v19n2-2020019>
- Rúa, S., Zuluaga, S., Redondo, A., Orozco-Duque, A., Restrepo, J., & Bustamante, J. (2012). Machine learning algorithms for real time arrhythmias detection in portable cardiac devices: Microcontroller implementation and comparative analysis. In 2012 XVII Symposium of Image, Signal Processing, and Artificial Vision (STSIVA), 50-55. <https://doi.org/10.1109/STSIVA.2012.6340556>
- Saadatfar, H., Khosravi, S., Joloudari, J., Mosavi, A., & Shamshirband, S. (2020). A New K-Nearest Neighbors Classifier for Big Data Based on Efficient Data Pruning. *Mathematics*, 8(2), Article 2. <https://doi.org/10.3390/math8020286>
- Sarker, I., Kayes, A., & Watters, P. (2019a). Effectiveness analysis of machine learning classification models for predicting personalized context-aware smartphone usage. *Journal of Big Data*, 6(1), 57. <https://doi.org/10.1186/s40537-019-0219-y>
- Sarker, I., Kayes, A., & Watters, P. (2019b). Effectiveness analysis of machine learning classification models for predicting personalized context-aware smartphone usage. *Journal of Big Data*, 6(1), 57. <https://doi.org/10.1186/s40537-019-0219-y>
- Skvorchevsky, A. (2023). Electronic Load Sensing for Integrating Electro-Hydraulic Mechatronic Actuators with Industry 4.0 and 5.0 Components. In *International Conference on Reliable Systems Engineering* (pp. 440-455). Cham: Springer Nature Switzerland. https://doi.org/10.1007/978-3-031-40628-7_37
- Thielen, N., Wagner, M., Meier, S., Voigt, C., & Franke, J. (2023). Anomaly Detection for Dispensing of Solder Paste on 3D Circuit Carriers Using Machine Learning. In 2023 IEEE

25th Electronics Packaging Technology Conference (EPTC) (pp. 932-937). IEEE.
<https://doi.org/10.1109/EPTC59621.2023.10457873>

Van, K., Vrancx, P., De Hauwere, Y.-M., Nowé, A., Hostens, E., & Lauwerys, C. (2014). Tuning hydrostatic two-output drive-train controllers using reinforcement learning. *Mechatronics*, 24(8), 975-985. <https://doi.org/10.1016/j.mechatronics.2014.07.005>

Yuan, D., Huang, J., Yang, X., & Cui, J. (2020). Improved random forest classification approach based on hybrid clustering selection. In 2020 Chinese Automation Congress (CAC), 1559-1563. <https://doi.org/10.1109/CAC51589.2020.9326711>

Zaitceva, I., & Andrievsky, B. (2022). Methods of Intelligent Control in Mechatronics and Robotic Engineering: A Survey. *Electronics*, 11(15), Article 15. <https://doi.org/10.3390/electronics11152443>

Zamudio-Ramirez, I., Osornio-Rios, R., Antonino-Daviu, J., Cureño-Osornio, J., & Saucedo-Dorantes, J.-J. (2021). Gradual Wear Diagnosis of Outer-Race Rolling Bearing Faults through Artificial Intelligence Methods and Stray Flux Signals. *Electronics*, 10(12), Article 12. <https://doi.org/10.3390/electronics10121486>

Zhang, W., Yang, D., & Wang, H. (2019a). Data-Driven Methods for Predictive Maintenance of Industrial Equipment: A Survey. *IEEE Systems Journal*, 13(3), 2213-2227. *IEEE Systems Journal*. <https://doi.org/10.1109/JSYST.2019.2905565>

Zhang, X., Xue, R., Yang, Y., Cheng, L., & Fang, Y. (2016b). Learning time-optimal anti-swing trajectories for overhead crane systems. In *Advances in Neural Networks—ISNN 2016: 13th International Symposium on Neural Networks, ISNN 2016, St. Petersburg, Russia, July 6-8, 2016, Proceedings 13* (pp. 338-345). Springer International Publishing. https://doi.org/10.1007/978-3-319-40663-3_39

Zhang, Y., Beudaert, X., Argandoña, J., Ratchev, S., & Munoa, J. (2020c). A CPPS based on GBDT for predicting failure events in milling. *The International Journal of Advanced Manufacturing Technology*, 111(1), 341-357. <https://doi.org/10.1007/s00170-020-06078-z>

Técnicas y aplicaciones de Machine Learning en el campo de la Mecatrónica: Una Revisión Sistemática de
Literatura

©2024 por los autores. Este artículo es de acceso abierto y distribuido según los términos y condiciones de la licencia Creative Commons
Atribución-NoComercial-CompartirIgual 4.0 Internacional (CC BY-NC-SA 4.0)
(<https://creativecommons.org/licenses/by-nc-sa/4.0/>).|