

Aplicación de algoritmos de inteligencia artificial en PLC para mantenimiento predictivo industrial: una revisión de literatura

Application of artificial intelligence algorithms in PLCs for industrial predictive maintenance: a literature review

Guillermo Raúl Tumalli Naranjo¹, Jonnathan Ismael Chamba Cruz², Guido George Ovaco Sandoya³, William Oswaldo Toapanta Tayupanta⁴

¹ Universidad UTE, Sede Santo Domingo, Santo Domingo, Santo Domingo de los Tsáchilas, Ecuador,
guillermo.tumalli@ute.edu.ec

DOI: <https://doi.org/10.61236/ciya.v10i1.1236>

Recibido: 18 de octubre de 2025 • Revisión aceptada: 12 de diciembre de 2025

Resumen

Este trabajo revisa cómo se están usando algoritmos de inteligencia artificial junto con los PLC para hacer mantenimiento predictivo en la industria. En los últimos años, muchas empresas han empezado a generar grandes cantidades de datos y a conectar más sensores, así que ahora es posible analizar el comportamiento de las máquinas con más detalle. La IA ayuda a detectar fallas antes de que ocurran y a planificar mejor las intervenciones. Para la revisión se siguió un proceso ordenado. Se buscó información solo en Scopus, entre 2020 y 2025. Se usaron palabras clave relacionadas con PLC, mantenimiento y algoritmos de IA. Después se filtraron los artículos según su importancia y si realmente aportaban resultados útiles. Al final se seleccionaron 18 estudios que cumplían con los criterios. Algunos autores usan computación en el borde para que los modelos corran cerca del equipo. Otros prefieren enviar los datos a la nube. También aparece bastante el uso de IoT y IIoT para conectar sensores y plataformas de monitoreo. En casi todos los casos, la IA mejora la detección de fallas, reduce paradas no planificadas y ayuda a tomar decisiones más rápidas.

Palabras claves: PLC, Inteligencia Artificial, Revisión de literatura, guías Prisma.

Abstract

This paper reviews how artificial intelligence algorithms are being used in conjunction with PLCs to perform predictive maintenance in industry. In recent years, many companies have begun to generate large amounts of data and connect more sensors, making it possible to analyze machine behavior in greater detail. AI helps detect faults before they occur and better plan interventions. An orderly process was followed for the review. Information was searched for only in Scopus, between 2020 and 2025. Keywords related to PLCs, maintenance, and AI algorithms were used. The articles were then filtered according to their importance and whether they actually provided useful results. In the end, 18 studies that met the criteria were selected. Some authors use edge computing to run models close to the equipment. Others prefer to send the data to the cloud. The use of IoT and IIoT to connect sensors and monitoring platforms also appears quite frequently. In almost all cases, AI improves fault detection, reduces unplanned downtime, and helps make faster decisions.

Keywords: PLC, Artificial Intelligence, Literature Review, Prisma guidelines.

1. INTRODUCCIÓN

En los últimos años, el mantenimiento predictivo ha pasado de ser una práctica complementaria para convertirse en una necesidad estratégica dentro de las organizaciones que avanzan hacia la Industria 4.0. La incorporación de tecnologías digitales y sistemas inteligentes ha impulsado nuevos enfoques para mejorar la disponibilidad de los equipos, disminuir los gastos asociados a fallas imprevistas y garantizar operaciones más estables [1]. En este entorno, los controladores lógicos programables (PLC) continúan siendo el pilar de la automatización industrial, pues sobre ellos recae la ejecución precisa y en tiempo real de las rutinas que permiten mantener operativos los procesos y coordinar los distintos elementos de una planta. Aun así, su diseño original estuvo orientado a tareas de control deterministas, por lo que no estaban preparados para manejar análisis complejos de datos, planteando así la necesidad de dotarlos de capacidades más avanzadas mediante técnicas de inteligencia artificial (IA) [2].

La incorporación de IA dentro de sistemas basados en PLC supone un punto de encuentro entre la automatización tradicional y las metodologías actuales de análisis de datos. Cuando se integran modelos de aprendizaje automático y aprendizaje profundo, los PLC pueden trabajar con información proveniente de sensores, variadores o redes industriales, no solo para supervisar

variables, sino también para identificar señales tempranas de deterioro o comportamientos fuera de lo habitual [3]. Este tipo de análisis permite intervenir antes de que aparezcan fallas graves, prolongar la vida útil de los equipos y disminuir considerablemente los costos derivados de interrupciones no planificadas [4].

En los últimos diez años, varios estudios han mostrado resultados prometedores en la aplicación de algoritmos de machine y deep learning para anticipar fallos y evitar desastres a nivel industrial. Estas contribuciones demuestran que la integración entre IA y PLC es viable y se perfila como una línea de investigación con alto potencial para transformar la manera en que las industrias gestionan sus procesos de mantenimiento [5], [6].

La integración de IA en los PLC conlleva un cambio de esquema en el mantenimiento industrial. Permite dar el gran salto del enfoque preventivo al predictivo, en el que las decisiones se toman a partir del análisis y aprendizaje de patrones de grandes bases de datos. Esto ha facilitado el camino hacia el mantenimiento 4.0 [7], [8].

A pesar de todo lo mencionado, esta integración todavía necesita ser explorada con más profundidad, entender cuál es la línea base y las posibilidades a futuro, i.e., limitaciones, retos y beneficios. Por lo descrito en párrafos anteriores, este trabajo presenta una revisión de literatura

sobre el uso de algoritmos de inteligencia artificial en sistemas PLC aplicados al mantenimiento predictivo.

2. METODOLOGÍA

Basados en otras revisiones de literatura, este trabajo emplea las guías PRISMA (Elementos de Informes Preferidos para Revisiones Sistemáticas y Metaanálisis). Esta herramienta permite estructurar de manera clara y jerárquica la literatura encontrada para reportar de manera transparente diversos resultados [9]. El objetivo de PRISMA no es imponer una camisa de fuerza, sino más bien, servir de apoyo para asegurar que los datos recogidos sean relevantes, los criterios de inclusión y exclusión bien definidos, y que el proceso empleado pueda ser replicado de manera sencilla [10], [11].

Bajo estos parámetros, la revisión empezó con la consulta de información en la base de datos SCOPUS. Este proceso se dividió en tres partes:

(i) formulación de preguntas de investigación, (ii) búsqueda documental (iii) selección de artículos.

2.1.Preguntas de investigación

Para seguir alineados con los objetivos planteados en esta investigación, se crearon tres preguntas de investigación. Estas se presentan en la Tabla 1.

Tabla 1. Preguntas de Investigación.

Código	Pregunta de investigación
P1	¿Cuáles son los principales algoritmos de inteligencia artificial aplicados en sistemas PLC para mantenimiento predictivo industrial?
P2	¿Qué metodologías o arquitecturas de integración entre IA y PLC se reportan con mayor frecuencia en la literatura científica reciente?
P3	¿Qué beneficios y desafíos se identifican en la implementación de IA en PLC para el mantenimiento predictivo en comparación con los métodos tradicionales?

2.2.Búsqueda documental

Se exploraron fuentes informativas buscando los estudios más relevantes sobre el empleo de algoritmos de inteligencia artificial, en sistemas PLC para mantenimiento predictivo. Con el fin de garantizar la rigurosidad académica de los datos, este estudio solo se enfocó en un repositorio de renombre: Scopus.

El periodo de análisis cubrió 2020 a 2025, un lapso de tiempo durante el cual el uso de la IA en la automatización industrial, y el mantenimiento

basado en datos, experimentó un alza significativa. Para la búsqueda, se emplearon operadores booleanos, y diversas combinaciones de palabras clave en inglés, ya que es el idioma donde usualmente se publican los trabajos académicos sobre el tema.

La cadena de búsqueda empleada fue: ("programmable logic controller" OR "PLC") AND ("predictive maintenance" OR "intelligent maintenance" OR "condition monitoring") AND ("artificial intelligence" OR "machine learning" OR "deep learning" OR "neural network").

2.3. Selección de artículos

Este proceso se enfocó en tres etapas: *identificación de estudios, cribado y selección final*. En la primera, se coleccionaron todos los artículos resultantes de la cadena de búsqueda. En la segunda fase, se definieron varios criterios para elegir artículos apropiados. Estos se presentan en la Tabla 2.

Tabla 2. Criterios de elegibilidad.

Criterio	Descripción
Diseño del estudio	Selección de artículos cuyo contenido detalle el uso de algoritmos de IA en PLC enfocado

Criterio	Descripción
	al mantenimiento predictivo en la industria.
Rango temporal	Se incluyeron artículos publicados entre 2020 y 2025. Aquellos que no cumplieron este criterio fueron excluidos.
Idioma	Solo se consideraron publicaciones escritas en inglés, debido a su predominio en la difusión científica internacional.
Estado de publicación	Se seleccionaron artículos publicados en revistas o congresos indexados y revisados por pares, verificando que contaran con DOI (Digital Object Identifier).

Tras la búsqueda inicial, los documentos hallados se organizaron y evaluaron según su pertinencia. Esto se realizó evaluando el título, el resumen y las palabras clave. Se dio prioridad a los artículos más recientes (respetando los límites de tiempo impuestos) y a aquellos que presentaban resultados aplicados en entornos industriales reales.

Durante esta fase se desecharon publicaciones que no aportaban evidencia sólida en la combinación PLC e inteligencia artificial. También se verificaron las referencias incluidas en cada artículo.

Finalmente, los artículos que cumplieron con todos los criterios fueron revisados nuevamente por dos investigadores con experiencia en automatización industrial, mantenimiento 4.0 e inteligencia artificial, quienes validaron la pertinencia y consistencia de la selección final. El detalle de los artículos obtenidos en cada fase se puede observar en la figura 1. Esto correspondió a la fase tres.

El análisis de co-ocurrencia de palabras clave se realizó mediante VOSviewer (ver figura 2), considerando un umbral mínimo de dos apariciones por término. El mapa generado permitió identificar los conceptos centrales y las relaciones temáticas predominantes en la literatura actual sobre inteligencia artificial aplicada a PLC para mantenimiento predictivo.

Los resultados muestran que predictive maintenance y machine learning constituyen los núcleos temáticos más fuertes, evidenciando su rol como pilares conceptuales en las investigaciones recientes. Ambos términos presentan los mayores valores de total link strength, lo que demuestra su amplia interconexión con otras áreas tecnológicas.

En torno a estos núcleos se forman varios clústeres temáticos. El clúster rojo agrupa conceptos asociados al análisis predictivo, tales como regression analysis, learning systems, internet of things, programmable logic controllers e industry

4.0, reflejando la relación directa entre PLC, IA y estrategias modernas de mantenimiento. El clúster verde concentra temas vinculados con industrial automation, edge computing, anomaly detection y artificial neural networks, lo que evidencia el interés por arquitecturas descentralizadas y de procesamiento distribuido para la detección temprana de fallas.




Figura 1. Flujograma PRISMA.

Por otro lado, el clúster azul integra términos más tradicionales como automation, control system, condition monitoring y artificial intelligence, que representan la base conceptual del mantenimiento industrial y su transición hacia modelos inteligentes. Finalmente, los términos periféricos del mapa complementan las líneas de investigación relacionadas con decision making, big data, cloud computing y condition-based maintenance, tecnologías habilitadoras que soportan la implementación de modelos predictivos en entornos industriales.

En conjunto, el mapa de co-ocurrencias confirma que la integración de algoritmos de IA en PLC constituye una línea ascendente de investigación, fuertemente vinculada al mantenimiento predictivo, la automatización avanzada y los sistemas ciberfísicos propios de la Industria 4.0.




Figura 2. Diagrama de coocurrencia de palabras clave.

Por otra parte, el análisis de coautoría se realizó utilizando un umbral mínimo de un documento por autor. De los 72 autores identificados en el corpus analizado, únicamente siete conformaron un grupo conectado dentro de la red, mientras que el resto no presentó vínculos de colaboración entre sí (ver figura 3).

La red resultante evidencia un único clúster cohesionado, compuesto por investigadores que han trabajado conjuntamente en múltiples publicaciones relacionadas con la aplicación de técnicas inteligentes para el mantenimiento industrial, entre ellos: Alladio E., Pagliari R., Leogrande V., Pozzi F., Foglio P., Baricco M. y Vincenti M.

Este comportamiento es común en revisiones de alcance reducido o en áreas de investigación emergentes, donde la producción científica tiende a ser dispersa y los grupos de trabajo están fragmentados. En consecuencia, la red de coautoría refleja un panorama en el que predominan trabajos individuales o colaboraciones aisladas, con un único grupo activo que concentra la mayor parte de las conexiones dentro del dominio estudiado. La información más relevante ha sido resumida en la tabla 3. Aquí, se resume la contribución de cada artículo y la tecnología de la industria 4.0 empleada.




Figura 3. Diagrama de coocurrencia de autores.

Tabla 3. Tecnologías involucradas en los artículos seleccionados.

Código	Título	Año	Enfoque principal / Contribución	Tecnología 4.0 involucrada
P1	AI-based condition monitoring of photocouplers to enhance the maintenance strategy for digital	2025	Sistema de monitoreo basado en IA para dispositivos fotocopladores en sistemas de protección digital.	Inteligencia artificial, monitoreo de condición, PLC

Código	Título	Año	Enfoque principal / Contribución	Tecnología 4.0 involucrada
	reactor protection systems			
P2	A Computational Intelligence Framework for Industry 4.0-based Intelligent Motion Control using AI-Integrated PLCs	2025	Marco de control inteligente de movimiento integrando PLC con IA y aprendizaje automático.	IA, aprendizaje automático, PLC, IoT
P3	Predictive maintenance based on IIoT and machine learning aligned with Industry 4.0: a case study in waste-water treatment plant	2025	Mantenimiento predictivo mediante IIoT y aprendizaje automático en una planta de tratamiento de aguas.	IIoT, aprendizaje automático, PLC

Código	Título	Año	Enfoque principal / Contribución	Tecnología 4.0 involucrada
P4	Assessment of Conveyor Telemetry System in a Manufacturing Firm	2025	Sistema de telemetría con sensores industriales, PLC y paneles de control para mantenimiento.	IoT industrial, PLC, telemetría
P5	Industrial Automation and Data Processing Techniques in IoT-Based Digital Twin Design for Thermal Equipment	2025	Diseño de gemelo digital IoT para equipos térmicos con sensores industriales.	Gemelo digital, IoT, PLC
P6	Overview of implementation principles of artificial intelligence methods in industrial control systems	2025	Revisión sobre la implementación de IA en sistemas de control industrial basados en PLC.	Inteligencia artificial, PLC

Código	Título	Año	Enfoque principal / Contribución	Tecnología 4.0 involucrada
P7	Integrating Machine Learning for Predictive Maintenance on Resource-Constrained PLCs	2025	Aprendizaje automático implementado en PLC de bajos recursos para mantenimiento predictivo.	Aprendizaje automático, computación en el borde, PLC
P8	Leveraging the Potential of Novel Data in Power Line Communication of Electricity Grids	2025	Uso de datos provenientes de comunicaciones por línea eléctrica para mantenimiento y detección de fallas.	Big Data, aprendizaje automático
P9	PLC based laser scanning system for conveyor belt surface monitoring	2024	Sistema basado en PLC y visión artificial para inspección de bandas	Visión artificial, aprendizaje profundo, PLC

Código	Título	Año	Enfoque principal / Contribución	Tecnología 4.0 involucrada
			transportadoras.	
P10	Innovative Approaches in Railway Management using Big Data and AI	2024	Uso de Big Data e IA para mantenimiento predictivo en infraestructura ferroviaria.	Big Data, inteligencia artificial
P11	Estimation of Tool Life in the Milling Process—Testing Regression Models	2023	Predicción de vida útil de herramienta mediante modelos de regresión y redes neuronales.	Aprendizaje automático, IIoT
P12	LSTM based AI predictive maintenance technique for OEE improvement in TPM	2023	Modelo LSTM de IA para predicción de fallas y mejora del OEE.	Aprendizaje profundo, IIoT

Código	Título	Año	Enfoque principal / Contribución	Tecnología 4.0 involucrada
	implementing plant			
P13	Anomaly Detection for Hydraulic Power Units—A Case Study	2023	Detección de anomalías mediante IoT, PLC y modelos SVM en unidades hidráulicas.	IoT, aprendizaje automático, computación en la nube
P14	Near-optimal multi-accelerator architectures for predictive maintenance at the edge	2023	Evaluación de arquitecturas FPGA/CPU para mantenimiento predictivo en el borde.	Computación en el borde, FPGA, ML
P15	Predictive Maintenance : An Embedded System Approach	2023	Mantenimiento predictivo mediante sistemas embebidos para análisis en tiempo real.	Sistemas embebidos, computación en el borde

Código	Título	Año	Enfoque principal / Contribución	Tecnología 4.0 involucrada
P16	The “DOLPHIN S” Project: A Low-Cost Real-Time Multivariate Process Control System integration for predictive process adjustment and cloud computing-based condition monitoring	2021	Control multivariante basado en datos de PLC bajo modelos PCA y SIMCA.	Aprendizaje automático, PLC
P17		2021	Integración PLC–nube–ML para ajuste predictivo y monitoreo basado en condición.	Computación en la nube, IA, PLC
P18	Increase food production efficiency using executable Digital Twin (xDT)	2021	Gemelo digital ejecutable para optimización y mantenimiento predictivo.	Gemelo digital, aprendizaje automático

3. RESULTADOS

3.1.Revisión de literatura

En [12], se presenta un enfoque para mejorar el mantenimiento de los sistemas de protección del reactor en plantas nucleares. Las prácticas actuales no permiten conocer con precisión el estado real de sus componentes durante la operación. Para cubrir esa necesidad, se plantea un esquema de monitoreo basado en inteligencia artificial. La propuesta combina reglas para asegurar la calidad de los datos y un modelo de IA que evalúa el estado de los componentes electrónicos. El estudio se centró en el fotocoplador, una pieza clave cuya falla puede afectar el desempeño del sistema. Los resultados mostraron que el sistema detecta fallas de forma anticipada y clasifica con precisión el estado del fotocoplador.

Por otro lado, el trabajo [13], plantea la integración de PLC, IoT e inteligencia artificial para transformar el controlador en un sistema inteligente. La solución se apoya en una base de datos alojada en la nube, donde se almacenan las señales del sistema y se generan análisis históricos que permiten tomar decisiones más informadas. Los resultados muestran métricas prometedoras, i.e., reducción del tiempo de respuesta del sistema, disminución significativa de errores en la trayectoria del movimiento y una precisión cercana al 95 % en los módulos predictivos.

En [14] se plantea un marco de control que combina inteligencia computacional, IA, IoT y PLCs. El sistema usa redes neuronales para que el control aprenda por sí mismo, lógica difusa para tomar decisiones en tiempo real y modelos de aprendizaje automático para predecir fallas antes de que ocurran. Además, una base de datos en la nube permite monitoreo continuo y decisiones basadas en datos. Las pruebas experimentales mostraron tiempos de respuesta un 30% más rápidos, una reducción del 40% en errores de movimiento y una precisión del 95% en el mantenimiento predictivo.

En [15], se mejora un sistema de mantenimiento predictivo basado en telemetría en una planta cervecera de Nigeria. El sistema integra varios sensores conectados a PLC, variadores y un panel en Grafana para ver los datos en tiempo real. Durante la operación se identificaron señales de falla entre las cuales se destacó: i) la corriente del motor subió hasta 3 A antes del apagado automático, ii) la vibración del rodamiento pasó de 0.5 a 4.6 mm/s, y; iii) la velocidad del transportador cayó de 7 a 2 cm/s. Estas alertas permitieron tomar acción oportuna antes de que se produzca una parada mayor.

El estudio presentado en [16], explora cómo los conceptos de gemelo digital pueden aplicarse a equipos térmicos industriales mediante una combinación de IoT, automatización y

herramientas de procesamiento de datos. Para cerrar esa brecha que existe entre lo teórico y real, desarrollan un framework que integra sensores, sistemas de adquisición y módulos en la nube con un gemelo digital validado en un banco de pruebas a escala. Con ello, se facilita la detección de estados anómalos y la planificación de acciones predictivas, y también se optimiza el consumo energético y se reducen impactos ambientales.

El artículo [17] corresponde a una revisión técnica que examina cómo las técnicas de inteligencia artificial están siendo incorporadas en los sistemas de control industrial. Se subraya que la evolución del hardware industrial ha permitido ejecutar algoritmos y modelos más actuales. El trabajo hace un repaso de modelado de procesos, control avanzado, control de calidad y mantenimiento predictivo.

En [18], se emplea una red neuronal convolucional (CNN) en un PLC de recursos limitados. El reto aquí fue adaptar los modelos desarrollados para que funcionen en hardware limitado. En este caso, la CNN se entrena con señales acústicas de un dispositivo mecánico para estimar su velocidad de rotación. Los resultados confirman que es posible realizar inferencia en tiempo real desde un PLC compacto, dando paso a aplicaciones predictivas sin depender totalmente de elementos externos.

En [19], los autores se enfocaron en redes eléctricas de baja tensión. Presentan el dataset FiN-2, que recopila una gran cantidad de datos provenientes de sensores distribuidos en una red real que alimenta a una cantidad alta de usuarios. El propósito del estudio fue demostrar que estas señales contienen patrones útiles para evaluar el estado de la infraestructura eléctrica. Se desarrollaron varios casos de estudio, desde la detección de fallas hasta la previsión de eventos y el análisis de estado.

Este trabajo [20], presenta un sistema para inspeccionar la superficie de bandas transportadoras en ambientes industriales inestables. La solución integra un PLC y un modelo de DL basado en YOLOv7. La arquitectura es compleja, combina una interfaz HMI con módulos de procesamiento en tiempo real, permitiendo la detección automática de defectos superficiales. En las pruebas realizadas, el sistema demostró ser eficiente a la hora de actuar antes de que los daños se agraven.

En [21], se propone una metodológica de análisis de datos a gran escala de la geometría de las vías del ferrocarril. A partir de las mediciones obtenidas durante las campanas de inspección ejecutadas por un vehículo especializado durante varios años se elaboran modelos de redes neuronales. El sistema obtiene una clasificación del estado de la vía, proyecta la evolución de determinados indicadores de condición y estima el momento óptimo para

llevar a cabo las tareas. Este enfoque permite anticiparse a la degradación del servicio y programar los mantenimientos de una forma más eficiente.

Los autores involucrados en [22] buscan identificar el modelo de regresión más adecuado para estimar la vida útil de herramientas de corte en procesos de fresado. Se realizaron experimentos controlados, recolectando datos de vibración, empleados posteriormente para entrenar diferentes modelos de predicción. Con métricas como R^2 , se concluyó que las redes neuronales bidimensionales con el solver LBFGS logran las mejores prestaciones. Con una adquisición de datos adecuada y un tratamiento cuidadoso de las variables, los autores demuestran que es posible estimar la vida útil de una herramienta con alta precisión.

En este trabajo, [23] se propone una técnica de mantenimiento predictivo basada en inteligencia artificial y redes LSTM (Long Short-Term Memory) para mejorar la disponibilidad y el OEE en una planta que implementa TPM (Total Productive Maintenance) bajo un contexto de transformación hacia Industria 4.0.

Se emplearon sensores conectados a PLC y supervisados mediante un sistema SCADA, lo que permitió capturar información operativa de manera continua. Una vez digitalizados, estos datos se enviaron a una plataforma donde se entrena una red

LSTM con el fin de estimar la vida útil remanente (RUL) de los componentes.

El trabajo publicado por [24], describe la implementación real de un sistema de detección de anomalías para unidades de potencia hidráulica. Los autores detallan la arquitectura completa: sensores conectados a PLC, un ordenador en el borde que procesa datos y comunicación con la nube (Microsoft Azure) donde se alojan modelos de detección de anomalías y servicios de almacenamiento.

Para la parte de análisis, el estudio compara enfoques estadísticos como One-Class SVM, para identificar desviaciones significativas en los datos de operación de la unidad hidráulica. Se discuten también distintos métodos de despliegue de los modelos a escala, así como los costos asociados a los recursos de nube utilizados. Aunque algunos detalles se mantienen reservados por tratarse de una implementación comercial, los resultados muestran que la solución es capaz de detectar anomalías de forma fiable y soportar decisiones de mantenimiento en un entorno industrial real. El artículo es valioso por mostrar la integración práctica de PLC, IoT, cloud y machine learning en un caso de uso concreto y sensible como la potencia hidráulica.

Este trabajo aborda el problema de diseñar arquitecturas de cómputo con múltiples

aceleradores (por ejemplo, FPGA + CPU) para aplicaciones de mantenimiento predictivo en el borde, donde existen restricciones de latencia, tamaño físico, coste, consumo energético y capacidad de procesamiento. Los autores proponen la metodología Resource-Constrained Accelerator Selection (RCS), que toma como entrada una biblioteca de arquitecturas de aceleradores escalables en recursos y selecciona la combinación que minimiza la latencia extremo a extremo, sujeto a las restricciones de recursos disponibles en un sistema SoC [25].

Una contribución importante es la introducción de ScaleFFT, un acelerador FFT escalable en recursos, necesario para habilitar RCS en aplicaciones típicas de mantenimiento predictivo basadas en análisis de señales. Al aplicar RCS y ScaleFFT a distintas aplicaciones de edge computing con diferentes anchos de banda de sensores, demuestran que es posible reducir la latencia hasta 2,4 veces en comparación con configuraciones convencionales que solo aceleran el algoritmo de ML. Además, muestran ejemplos en monitoreo de pozos de petróleo y vías férreas, evidenciando que una selección cuidadosa de aceleradores puede ofrecer beneficios significativos para sistemas de mantenimiento predictivo que operan bajo fuertes restricciones de hardware.

En este artículo [26], presenta un enfoque de mantenimiento predictivo sustentado en una arquitectura de computación en el borde (MEC), en la cual se utilizan dispositivos embebidos de bajo costo para procesar datos directamente en planta. Esta idea busca conservar las ventajas de la digitalización propia de la Industria 4.0, sin asumir los costos ni la dependencia que implican las soluciones completamente basadas en la nube. Para evaluar el rendimiento del sistema, los autores comparan la ejecución de un mismo modelo predictivo implementado en Python y con librerías ampliamente utilizadas en la comunidad científica en dos plataformas distintas: un equipo de escritorio y un dispositivo embebido.

El caso de estudio, desarrollado con datos simulados que representan tanto comportamientos normales como fallas, demuestra que el sistema embebido puede tomar decisiones con alta precisión. Esto abre una alternativa realista para pequeñas y medianas empresas que desean introducir mantenimiento predictivo, pero que no cuentan con el presupuesto para invertir en hardware industrial de alto desempeño.

El proyecto DOLPHINS surge como una colaboración entre industria, desarrolladores de software y el sector académico con el objetivo de diseñar un sistema de mantenimiento predictivo en tiempo real para una planta piloto dedicada al panelado de laterales de camiones. Lo más

atractivo del trabajo es que el sistema se construye a partir de la información ya disponible en los PLC instalados, sin recurrir a sensores adicionales. Estos datos principalmente señales binarias on/off se procesan como matrices dispersas, lo que obliga a utilizar técnicas de análisis multivariante específicas. Tras probar distintos modelos, los autores identifican que la combinación PCA–SIMCA ofrece el mejor equilibrio entre precisión y robustez [27].

En [28], se propone una arquitectura de integración para supervisar y ajustar de manera predictiva los procesos en un sistema automatizado de almacenamiento y recuperación (ASRS). El sistema recopila señales clave de vibración y temperatura mediante un PLC conectado a la red IoT, enviando la información a la nube para su análisis mediante algoritmos de machine learning.

Finalmente, en [29] se examina cómo la industria alimentaria puede potenciar sus procesos mediante el uso de gemelos digitales ejecutables. Se recurre a técnicas de reducción de modelos respaldadas por machine learning para generar representaciones más compactas, capaces de ejecutarse con rapidez en hardware de borde. Se integran con controladores que ajustan automáticamente el proceso según las condiciones detectadas.

3.2. Análisis descriptivo y estadísticas de los estudios seleccionados

La Figura 4 presenta la distribución de las principales tecnologías 4.0 identificadas en los 18 estudios analizados. El análisis confirma que, dentro del contexto del mantenimiento predictivo industrial, el PLC sigue siendo la plataforma tecnológica preferida para la integración en planta debido a su robustez. Con una menor representatividad se muestra IoT/IloT, identificado en siete de los estudios revisados, otras tecnologías, como la computación en el borde, Big Data y los gemelos digitales, aparecen con menor frecuencia. Aunque todavía no son predominantes, estas herramientas comienzan a jugar un papel clave en aplicaciones donde se requiere procesamiento inmediato.

Finalmente, se observa la presencia de tecnologías como visión artificial, sistemas embebidos, monitoreo de condición, telemetría y FPGA, cada una utilizada en un solo estudio. Estos casos muestran cómo el mantenimiento predictivo se está ampliando hacia soluciones altamente especializadas, diseñadas para entornos concretos y para responder a necesidades particulares de rendimiento, tiempos de reacción o capacidad de detección.




Figura 4. Frecuencia de tecnologías agrupadas.

La Figura 5 muestra la distribución temporal de los 18 artículos incluidos en esta revisión. Se observa que en el año 2025 ha existido un creciente interés de la comunidad científica por la integración de los dos elementos en estudio. Esto representa el 44,4 % del total. Este incremento puede asociarse al rápido avance del hardware industrial, la disponibilidad de librerías de IA optimizadas y la mayor adopción de arquitecturas IloT en las plantas de manufactura.

En segundo lugar, el 2023 aporta 5 artículos (27,8 %), confirmando que la línea de investigación ha mostrado un crecimiento sostenido en los últimos años. Por su parte, el 2021 aparece con 3 artículos (16,7 %), reflejando los trabajos iniciales que incorporaron técnicas de IA y análisis

multivariante en sistemas PLC. Finalmente, el 2024 contribuye con 2 artículos (11,1 %), manteniendo la tendencia ascendente y sirviendo como transición hacia el pico observado en 2025.

Esta distribución temporal evidencia una evolución acelerada del campo, con una clara intensificación de publicaciones entre 2023 y 2025. Esto sugiere que la integración PLC-IA es una línea de investigación emergente que continúa expandiéndose, impulsada por desarrollos recientes en edge computing, conectividad IIoT y técnicas avanzadas de modelado predictivo.




Figura 5. Distribución de artículos por año.

4. DISCUSIÓN

4.1.Respuesta a P1

El análisis de los artículos revela que los algoritmos más utilizados en entornos basados en PLC corresponden a modelos de aprendizaje supervisado, particularmente redes neuronales feedforward, redes neuronales convolucionales (CNN) comprimidas para ejecución en el borde, y modelos LSTM orientados a series temporales. Estas técnicas destacan porque permiten modelar relaciones no lineales entre señales industriales (corriente, vibración, acústica, temperatura) y la condición operativa de los activos, incluso cuando dichas relaciones no pueden expresarse mediante ecuaciones determinísticas típicas de la automatización clásica.

Además, se observa un uso frecuente de máquinas de soporte vectorial (SVM), especialmente en tareas de detección de anomalías en unidades hidráulicas, y de métodos multivariantes como PCA y SIMCA, empleados en sistemas PLC que solo disponen de señales binarias o discretas. Este tipo de modelos tiene la ventaja de ser computacionalmente livianos y de interpretarse con mayor facilidad dentro de un contexto industrial, lo que facilita su integración con lógica de control existente.

Finalmente, técnicas como árboles de decisión, XGBoost y regresiones avanzadas también

aparecen en aplicaciones específicas, sobre todo para estimar vida útil de herramientas, predecir degradación en infraestructura ferroviaria o identificar patrones anómalos en redes eléctricas mediante Big Data. En conjunto, los estudios muestran que, aunque la IA aplicada a PLC aún enfrenta restricciones de hardware, la tendencia dominante es adaptar algoritmos de ML de alta precisión para ejecutarse en arquitecturas ligeras, ya sea mediante compresión del modelo, cálculo en el borde o ejecución híbrida PLC–nube.

4.2.Respuesta a P2

Del análisis de los estudios se desprende que existen tres tipos de arquitecturas que se repiten con mayor frecuencia. La primera de ellas corresponde a los sistemas basados en PLC combinados con computación en el borde. De este modo, el controlador, se complementa con un dispositivo próximo que ejecuta los respectivos modelos de inteligencia artificial. Esta arquitectura es de utilidad en aplicaciones que requieren respuestas en tiempos de casi inmediato o para aquellas donde la información es muy sensible y no se quiere enviar la información fuera de la planta.

El segundo tipo de arquitectura es la integración PLC con la nube. En este caso, el controlador recopila las señales de campo y las envía a plataformas, como Azure, AWS entre otros. Allí se realizan tareas como la predicción de vida útil, la

clasificación de fallas o los análisis multivariantes. Este enfoque es común en sistemas de gran escala como, redes eléctricas o infraestructuras ferroviarias donde la cantidad de datos y la complejidad del análisis superan ampliamente la capacidad de procesamiento local.

Un tercer enfoque combina PLC con tecnologías IoT/IIoT. Aquí el PLC se vincula con sensores inteligentes, brokers MQTT y herramientas de visualización como Node-RED o Grafana. Esto permite consolidar información en tiempo real, generar alertas anticipadas y construir sistemas de telemetría industrial completos. Algunos trabajos, además, incorporan gemelos digitales ejecutables (xDT) y modelos de IA para estimar comportamientos futuros y mejorar la toma de decisiones.

La literatura coincide en que los PLC han dejado de ser dispositivos aislados para convertirse en nodos dentro de un ecosistema digital más amplio, donde la conectividad, la analítica avanzada y la inteligencia artificial trabajan de manera conjunta para habilitar nuevas capacidades predictivas y operativas.

4.3.Respuesta a P3

Los beneficios identificados en los estudios revisados son bastante claros y coinciden en la mayoría de los casos. Uno de los aspectos más

destacados es la capacidad de la inteligencia artificial, cuando se integra con sistemas PLC, para anticipar fallas con mucha más antelación que los métodos tradicionales. Los modelos entrenados con datos de operación real permiten reconocer comportamientos anómalos incluso antes de que aparezcan señales visibles para el personal técnico o para los sistemas de alarma convencionales. Esto se traduce directamente en mayores niveles de disponibilidad, confiabilidad y eficiencia global del proceso.

Otro aporte relevante es la posibilidad de migrar de estrategias de mantenimiento basadas en tiempo o en revisiones manuales hacia enfoques predictivos guiados por datos. En aplicaciones industriales se han reportado reducciones de costos de hasta un 60 %, acompañadas de diagnósticos oportunos. También se observa un avance preponderante en la capacidad de la IA para analizar señales como vibración o audio, así como patrones superficiales captados por visión artificial.

A pesar de todo lo mencionado en el texto anterior, la integración de estas tecnologías todavía tiene grandes desafíos. Uno de los más mencionados es la limitación de hardware de los PLC, lo que obliga a simplificar modelos, delegar procesos al borde o combinar capacidades locales con servicios en la nube. Por otra parte, existen inconvenientes relacionados con la calidad y disponibilidad de datos, especialmente en plantas que se siguen

manejando de forma tradicional. La ciberseguridad es otro punto que considerar, ya que las arquitecturas modernas suelen combinar PLC, IoT y plataformas cloud. Finalmente, varios de los estudios analizados en este trabajo destacan la necesidad de que el personal de mantenimiento adquiera nuevas habilidades digitales.

5. CONCLUSIONES

El análisis de los 18 estudios incluidos en esta revisión muestra que la incorporación de algoritmos de inteligencia artificial en sistemas PLC se ha convertido en una realidad. Los trabajos coinciden en que la IA ayuda a anticipar fallas, estimar la vida útil de los equipos y detectar comportamientos extraños que antes pasaban desapercibidos. Esto ha sido posible porque hoy existen más datos, más sensores y más tecnologías IIoT conectadas. También influyen las nuevas arquitecturas que combinan el PLC con procesamiento en la nube o en el borde.

La adopción de estas soluciones también enfrenta obstáculos que la literatura señala con frecuencia. Entre los más relevantes se encuentran las limitaciones de hardware propias de muchos PLC, la ausencia de estándares que faciliten la interoperabilidad, los retos vinculados al manejo de grandes volúmenes de datos y los riesgos inherentes a la ciberseguridad en entornos conectados. A ello se suma la necesidad de que los

equipos de mantenimiento desarrollen nuevas competencias digitales para aprovechar plenamente estas tecnologías. Todos estos factores influirán en la velocidad y profundidad con la que las industrias puedan implementar sistemas predictivos basados en IA.

Los resultados de esta revisión permiten afirmar que la convergencia entre PLC e inteligencia artificial constituye una tendencia firme y en expansión, que está redefiniendo la manera en que se conciben y gestionan las estrategias de mantenimiento. Conforme los entornos industriales avancen hacia niveles más altos de autonomía y conectividad, la IA dejará de ser un complemento para convertirse en una pieza central en la gestión del ciclo de vida de los activos y en el soporte a la toma de decisiones operativas.

6. BIBLIOGRAFÍA

- [1] M. Soori, B. Arezoo, and R. Dastres, “Virtual manufacturing in Industry 4.0: A review,” *Data Science and Management*, vol. 7, no. 1, pp. 47–63, Mar. 2024, doi: 10.1016/j.dsm.2023.10.006.
- [2] J. E. Naranjo, G. Caiza, R. Velastegui, M. Castro, A. Alarcon-Ortiz, and M. V. Garcia, “A Scoping Review of Pipeline Maintenance Methodologies Based on Industry 4.0,” *Sustainability*, vol. 14, no. 24, p. 16723, Dec. 2022, doi: 10.3390/su142416723.
- [3] J. Q. Yang, S. Zhou, D. Van Le, D. Ho, and R. Tan, “Improving Quality Control with Industrial AIoT at HP Factories: Experiences and Learned Lessons,” in *2021 18th Annual IEEE International Conference on Sensing, Communication, and Networking (SECON)*, IEEE, Jul. 2021, pp. 1–9. doi: 10.1109/SECON52354.2021.9491592.
- [4] A. Madamanchi, F. Rabbi, A. M. Sokolov, and N. U. I. Hossain, “A Machine Learning-Based Corrosion Level Prediction in the Oil and Gas Industry,” in *ICIMP 2024*, Basel Switzerland: MDPI, Oct. 2024, p. 38. doi: 10.3390/engproc2024076038.
- [5] S. Mediseti, V. Y. Kotiboyina, and A. M. Gollapudi, “Modelling and simulation of a PLC based automatic stamping and inspection system incorporated with a pick and place pneumatic suction cup using Factory I/O,” 2024, p. 020049. doi: 10.1063/5.0213847.
- [6] S. Mainali and C. Li, “A robotic fish processing line enhanced by machine learning,” *Aquac Eng*, vol. 108, p. 102481, Mar. 2025, doi: 10.1016/j.aquaeng.2024.102481.

- [7] G. Wu, Z. Chen, and J. Dang, *Intelligent Bridge Maintenance and Management*. Singapore: Springer Nature Singapore, 2024. doi: 10.1007/978-981-97-3827-4.
- [8] W. Istiono and A. N. Wira Pratama, “Innovative virtual reality solutions for technical training in heavy construction equipment repair and maintenance,” *Indonesian Journal of Electrical Engineering and Computer Science*, vol. 37, no. 1, p. 627, Jan. 2025, doi: 10.11591/ijeecs.v37.i1.pp627-635.
- [9] J. E. Naranjo, D. G. Sanchez, A. Robalino-Lopez, P. Robalino-Lopez, A. Alarcon-Ortiz, and M. V. Garcia, “A Scoping Review on Virtual Reality-Based Industrial Training,” *Applied Sciences*, vol. 10, no. 22, p. 8224, Nov. 2020, doi: 10.3390/app10228224.
- [10] Z. Farshadfar, T. Mucha, and K. Tanskanen, “Leveraging Machine Learning for Advancing Circular Supply Chains: A Systematic Literature Review,” *Logistics*, vol. 8, no. 4, p. 108, Oct. 2024, doi: 10.3390/logistics8040108.
- [11] L. A. Cárdenas-Robledo, Ó. Hernández-Uribe, C. Reta, and J. A. Cantoral-Ceballos, “Extended reality applications in industry 4.0. – A systematic literature review,” *Telematics and Informatics*, vol. 73, p. 101863, Sep. 2022, doi: 10.1016/j.tele.2022.101863.
- [12] H. J. Lee, H. S. Jo, M. G. Na, and C. H. Kim, “AI-based condition monitoring of photocouplers to enhance the maintenance strategy for digital reactor protection systems,” *Nuclear Engineering and Technology*, vol. 58, no. 2, 2025, doi: 10.1016/j.net.2025.103958.
- [13] Z. L. Mayaluri, A. K. Naik, R. Samantaray, A. Rath, and G. Panda, “A Computational Intelligence Framework for Industry 4.0-based Intelligent Motion Control using AI-Integrated PLCs,” *J Sci Ind Res (India)*, vol. 84, no. 9, pp. 945–956, 2025, doi: 10.56042/jsir.v84i9.18846.
- [14] S. Abd-Elhaleem, A. Zanfai, and M. Hamdy, “Predictive maintenance based on IIoT and machine learning aligned with industry 4.0: a case study in waste-water treatment plant,” *Neural Comput Appl*, vol. 37, no. 24, pp. 20383–20407, 2025, doi: 10.1007/s00521-025-11463-4.
- [15] O. Otuagoma Smith, E. Obuseh Emmanuel, O. Oyubu Akpovi, O. Antony, E. O. Jonathan, and T. B. Ronald, “Assessment of Conveyor Telemetry System in a Manufacturing Firm: A Case Study of a Brewery in Eastern Nigeria,” *NIPES - Journal of Science and Technology Research*, vol. 7, no. 2, pp. 44–58, 2025, doi: 10.37933/nipes/7.2.2025.3.
- [16] S. S. Chaudhari, K. S. Bhole, and S. B. Rane, “Industrial Automation and Data Processing

Techniques in IoT-Based Digital Twin Design for Thermal Equipment: A case study,” *Journal of The Institution of Engineers (India): Series C*, vol. 106, no. 2, pp. 553–569, 2025, doi: 10.1007/s40032-025-01164-1.

[17] L. Körösi and S. Kajan, “Overview of implementation principles of artificial intelligence methods in industrial control systems,” *Journal of Electrical Engineering*, vol. 76, no. 1, pp. 99–105, 2025, doi: 10.2478/jee-2025-0010.

[18] R. Mennilli, L. Mazza, and A. Mura, “Integrating Machine Learning for Predictive Maintenance on Resource-Constrained PLCs: A Feasibility Study,” *Sensors*, vol. 25, no. 2, 2025, doi: 10.3390/s25020537.

[19] C. Balada, M. Bondorf, S. Ahmed, M. Zdrallek, and A. Dengel, “Leveraging the Potential of Novel Data in Power Line Communication of Electricity Grids,” *IEEE Access*, vol. 13, pp. 71662–71672, 2025, doi: 10.1109/ACCESS.2025.3560811.

[20] R. Wang *et al.*, “PLC based laser scanning system for conveyor belt surface monitoring,” *Sci Rep*, vol. 14, no. 1, 2024, doi: 10.1038/s41598-024-78985-0.

[21] R. Nagy, F. Horvat, and S. Fischer, “Innovative Approaches in Railway Management:

Leveraging Big Data and Artificial Intelligence for Predictive Maintenance of Track Geometry,” *Tehnicki Vjesnik*, vol. 31, no. 4, pp. 1245–1259, 2024, doi: 10.17559/TV-20240420001479.

[22] A. Paszkiewicz, G. Piecuch, T. Żabiński, M. Bolanowski, M. Salach, and D. Rączka, “Estimation of Tool Life in the Milling Process—Testing Regression Models,” *Sensors*, vol. 23, no. 23, 2023, doi: 10.3390/s23239346.

[23] R. Mohan, J. P. Preetha Roselyn, and R. A. Uthra, “LSTM based artificial intelligence predictive maintenance technique for availability rate and OEE improvement in a TPM implementing plant through Industry 4.0 transformation,” *J Qual Maint Eng*, vol. 29, no. 4, pp. 763–798, 2023, doi: 10.1108/JQME-07-2022-0041.

[24] P. Fic, A. Czornik, and P. Rosikowski, “Anomaly Detection for Hydraulic Power Units—A Case Study,” *Future Internet*, vol. 15, no. 6, 2023, doi: 10.3390/fi15060206.

[25] M. Koraei, J. M. Cebrian Gonzalez, and M. Jahre, “Near-optimal multi-accelerator architectures for predictive maintenance at the edge,” *Future Generation Computer Systems*, vol. 140, pp. 331–343, 2023, doi: 10.1016/j.future.2022.10.030.

[26] I. T. Franco and R. M. de Figueiredo, “Predictive Maintenance: An Embedded System Approach,” *Journal of Control, Automation and Electrical Systems*, vol. 34, no. 1, pp. 60–72, 2023, doi: 10.1007/s40313-022-00949-4.

[27] E. Alladio *et al.*, “The ‘DOLPHINS’ Project: A Low-Cost Real-Time Multivariate Process Control From Large Sensor Arrays Providing Sparse Binary Data,” *Front Chem*, vol. 9, 2021, doi: 10.3389/fchem.2021.734132.

[28] S. Baek, “System integration for predictive process adjustment and cloud computing-based real-time condition monitoring of vibration sensor signals in automated storage and retrieval systems,” *International Journal of Advanced Manufacturing Technology*, vol. 113, no. 3–4, pp. 955–966, 2021, doi: 10.1007/s00170-021-06652-z.

[29] T. Eppinger, G. Longwell, P. Mas, K. Goodheart, U. Badiali, and R. Aglave, “Increase food production efficiency using the executable Digital Twin (xDT),” *Chem Eng Trans*, vol. 87, pp. 37–42, 2021, doi: 10.3303/CET2187007.