

Análisis del uso de Machine Learning como herramienta de optimización en sistemas PLC para procesos industriales inteligentes¹

Andrés Reinaldo Herrera Díaz²
Oscar Fernando Becerra Angarita³

Resumen

El presente trabajo desarrolla una revisión sistemática de la literatura orientada al análisis del uso de Machine Learning (ML) como herramienta de optimización en sistemas de Controladores Lógicos Programables (PLC) aplicados a procesos industriales inteligentes dentro del contexto de la Industria 4.0. Para ello, se realiza una evaluación crítica de la literatura científica con el fin de identificar las principales aplicaciones, beneficios, limitaciones, desafíos y tendencias de investigación asociadas a la integración de técnicas de aprendizaje automático en arquitecturas de automatización industrial basadas en PLC. Los resultados evidencian que el Machine Learning fortalece las capacidades de los sistemas PLC mediante aplicaciones en la optimización de procesos, el monitoreo inteligente, el mantenimiento predictivo y la detección de fallas, favoreciendo una mayor eficiencia operativa y una mejor toma de decisiones.

Palabras claves: Controladores Lógicos Programables, análisis, beneficios.

Analysis of the use of Machine Learning as an optimization tool in PLC systems for intelligent industrial processes

Abstract

This paper presents a systematic literature review focused on the use of Machine Learning (ML) as an optimization tool in Programmable Logic Controller (PLC) systems applied to intelligent industrial processes within the context of Industry 4.0. To this end, a critical evaluation of scientific literature is conducted to identify the main applications, benefits, limitations, challenges, and research trends associated with integrating machine learning techniques into PLC-based industrial automation architecture. The results demonstrate that Machine Learning strengthens the capabilities of PLC systems through applications in process optimization, intelligent monitoring, predictive maintenance, and fault detection, leading to greater operational efficiency and improved decision-making.

Keywords: Programmable Logic Controllers, analysis, benefits.

¹ Artículo científico presentado como opción de grado para optar por el título de Ingeniero Mecatrónico.

² Autor: andresreinaldo.herrera@ustabuca.edu.co, Universidad Santo Tomás.

³ Director: Ingeniero electrónico, Magíster en Ingeniería eléctrica, oscar.becerra01@ustabuca.edu.co, Universidad Santo Tomás.

Introducción

La evolución de la Industria 4.0 ha impulsado la incorporación de tecnologías digitales avanzadas en los sistemas de producción con el propósito de mejorar la eficiencia, la flexibilidad y la competitividad de los procesos industriales. En este contexto, el Machine Learning (ML) se ha consolidado como una de las herramientas más relevantes para el análisis de datos industriales, permitiendo identificar patrones, generar modelos predictivos y apoyar la toma de decisiones basada en datos. Diversos estudios reportan aplicaciones exitosas de estas técnicas en mantenimiento predictivo, control de calidad, optimización de procesos, planificación de la producción y detección de anomalías, contribuyendo a la reducción de costos operativos y al incremento de la productividad en entornos de manufactura inteligente [2], [3].

Los Controladores Lógicos Programables (PLC) continúan siendo el elemento central de los sistemas de automatización industrial debido a su confiabilidad, capacidad de operación en tiempo real y amplia implementación en procesos productivos [4]. Sin embargo, el aumento en la complejidad de los entornos industriales modernos ha puesto de manifiesto las limitaciones de los enfoques tradicionales de automatización para responder a las crecientes necesidades de optimización, monitoreo inteligente y toma de decisiones autónoma [2]. Aunque las técnicas de Machine Learning han demostrado ser efectivas para abordar estos desafíos, su implementación en aplicaciones industriales se ha realizado tradicionalmente mediante plataformas externas, como servidores, computadores industriales o sistemas en la nube, debido a las restricciones de memoria, capacidad de procesamiento y tiempos de ciclo presentes en los PLC [4]. No obstante, los avances recientes en hardware industrial y las nuevas estrategias de optimización computacional han despertado un creciente interés por integrar modelos de aprendizaje automático directamente en estos dispositivos, acercando las capacidades de análisis, predicción y control inteligente al nivel operativo de los procesos industriales [4].

La literatura reciente evidencia que la integración de Machine Learning en sistemas PLC puede aportar beneficios significativos en términos de monitoreo inteligente, mantenimiento predictivo, detección temprana de fallas, optimización de recursos y mejora de la eficiencia operativa [2], [3], [4]. Asimismo, esta integración favorece la toma de decisiones en tiempo real y reduce la dependencia de hardware adicional para el procesamiento de datos [4]. Sin embargo, persisten desafíos asociados a las limitaciones computacionales de los PLC, los tiempos de ejecución requeridos por los algoritmos de aprendizaje automático, la validación de los modelos y su incorporación dentro de arquitecturas industriales complejas [1], [4]. A pesar del creciente interés académico e industrial en esta temática, la diversidad de enfoques, metodologías y aplicaciones reportadas dificulta la identificación de tendencias consolidadas, beneficios comunes y limitaciones técnicas compartidas.

En consecuencia, resulta necesario realizar una revisión sistemática de la literatura que permita analizar de manera integrada el estado actual del conocimiento sobre la aplicación de Machine Learning en sistemas PLC para procesos industriales inteligentes. Aunque existen numerosas investigaciones sobre Machine Learning aplicado a la manufactura inteligente y a la Industria 4.0, la mayoría de ellas centran su atención en aplicaciones ejecutadas mediante plataformas externas, como servicios en la nube, computadores industriales o arquitecturas Edge Computing, mientras que son menos frecuentes los estudios que analizan de forma específica la incorporación de

modelos de aprendizaje automático directamente en los PLC, así como las capacidades, limitaciones y estrategias que hacen posible esta integración. Esta dispersión dificulta identificar el nivel de madurez de las soluciones propuestas, las técnicas de Machine Learning más apropiadas para cada contexto industrial y los desafíos técnicos que aún limitan su implementación en dispositivos de control industrial. En este contexto, el presente trabajo tiene como objetivo analizar el uso de técnicas de Machine Learning como herramientas de optimización en sistemas PLC dentro de procesos industriales inteligentes, identificando sus principales aplicaciones, beneficios, limitaciones y contribuciones al desarrollo de la Industria 4.0, con el fin de proporcionar un marco de referencia que facilite la selección de la técnica de Machine Learning más adecuada según las características del problema industrial que se desea resolver.

Metodología de análisis y recolección de datos

Tipo de investigación

Este estudio se desarrolló mediante una revisión sistemática de literatura (RSL), metodología que permite identificar, evaluar y sintetizar de manera estructurada la evidencia científica disponible sobre un tema específico. La revisión se enfocó en el análisis del uso de técnicas de Machine Learning como herramientas de optimización en sistemas PLC dentro de procesos industriales inteligentes, con el propósito de identificar aplicaciones, beneficios, limitaciones y tendencias de investigación asociadas a esta temática.

Estrategia de búsqueda

La búsqueda bibliográfica se realizó en bases de datos científicas reconocidas por su cobertura en las áreas de ingeniería, automatización e inteligencia artificial. Para ello se empleó la siguiente ecuación de búsqueda:

("Machine Learning" OR "Deep Learning" OR "Artificial Intelligence" OR "AI" OR "Intelligent Processes") AND ("PLC" OR "Programmable Logic Controller")

La consulta fue aplicada en títulos, resúmenes y palabras clave de los documentos disponibles en las bases de datos IEEE Xplore y ScienceDirect, considerando publicaciones entre 2020 y 2026. El proceso de búsqueda se orientó a identificar investigaciones relacionadas con la integración de técnicas de aprendizaje automático en sistemas PLC y su aplicación en entornos industriales. Se incluyeron tanto artículos de revista como artículos de congreso indexados, debido a que en el área de automatización industrial una parte importante de los avances científicos más recientes se difunde inicialmente en actas de congresos, especialmente las publicadas por IEEE, las cuales cuentan con procesos de revisión por pares comparables a los de las revistas científicas. Por esta razón, ambos tipos de publicaciones fueron considerados fuentes válidas de evidencia para la presente revisión sistemática de literatura.

Criterios de inclusión y exclusión

Para garantizar la pertinencia de los documentos analizados se establecieron los siguientes criterios de inclusión:

- Artículos científicos, revisiones o publicaciones académicas relacionadas con Machine Learning, Inteligencia Artificial o Deep Learning aplicados a sistemas PLC.

- Estudios enfocados en procesos industriales, automatización, manufactura inteligente o Industria 4.0.
- Publicaciones disponibles en texto completo.
- Documentos publicados en revistas científicas o congresos indexados.

Por otra parte, se excluyeron:


- Trabajos duplicados.
- Documentos que abordaran PLC o Machine Learning de manera independiente sin evidenciar relación entre ambas tecnologías.
- Publicaciones sin información suficiente para el análisis de resultados.

Proceso de análisis de la información

Los documentos seleccionados fueron revisados y analizados de manera cualitativa. Posteriormente, la información fue organizada en categorías temáticas definidas a partir de los objetivos de la investigación. Estas categorías incluyeron:


- Aplicaciones del Machine Learning para la optimización de procesos industriales
- Machine Learning para el monitoreo y supervisión de sistemas PLC
- Machine Learning aplicado al mantenimiento predictivo.
- Algoritmos de Machine Learning empleados en sistemas PLC
- Beneficios obtenidos mediante la incorporación de Machine Learning en sistemas PLC.

Figura 1. *Diagrama de flujo de la metodología implementada.*



Nota: Esquema adaptado del diagrama de flujo.

Figura 2. Diagrama prisma para la selección de artículos.



Nota: Esquema adaptado de la metodología prisma.

Resultados

Aplicaciones del Machine Learning para la optimización de procesos industriales

Los estudios analizados evidencian que la aplicación del Machine Learning en sistemas basados en PLC ha evolucionado desde enfoques centrados exclusivamente en el control automático hacia soluciones integrales que abarcan la optimización de procesos, el mantenimiento predictivo, la asistencia a operadores y la automatización de la programación industrial. En conjunto, la literatura muestra una tendencia a complementar las capacidades tradicionales de los PLC mediante algoritmos inteligentes capaces de procesar información en tiempo real y adaptar el comportamiento del sistema según las condiciones del proceso.

Tabla 1. *Aplicaciones del Machine Learning para la optimización de procesos industriales identificadas en la literatura revisada*

Aplicación identificada	Técnica de Machine Learning o IA	Aplicación en PLC	Beneficio reportado	Artículos que lo sustentan
Optimización adaptativa del control	Redes neuronales BP + PID	Ajuste automático de parámetros de control	Eliminación del error estacionario, reducción del sobreimpulso y mayor precisión	Artículo [8].

Aplicación identificada	Técnica de Machine Learning o IA	Aplicación en PLC	Beneficio reportado	Artículos que lo sustentan
Mantenimiento predictivo	Modelos predictivos basados en IA	Diagnóstico y predicción de fallos en líneas inteligentes	Disminución del mantenimiento correctivo y mayor disponibilidad del sistema	Artículo [7]
Automatización inteligente mediante procesamiento local	Machine Learning en arquitecturas Dew Computing	Ejecución local de modelos sobre PLC y SCADA	Reducción de latencia y mayor disponibilidad del sistema	Artículo [6]
Interfaces inteligentes hombre-máquina	Reconocimiento de voz mediante ASR y Deep Learning	Control de PLC mediante comandos de voz	Reducción de tiempos muertos y mejora de la ergonomía del operador	Artículo [9]
Asistentes inteligentes para programación PLC	Large Language Models con RAG	Generación automática de código Structured Text	Disminución del tiempo de programación y validación automática del código	Artículo [5]

Nota: Tabla elaborada con la información de las fuentes consultadas.

Una de las aplicaciones más recurrentes corresponde a la optimización del control de procesos industriales mediante redes neuronales. Una de las investigaciones [8] propone un controlador PID adaptativo optimizado con una red neuronal Backpropagation (BP), implementado sobre un PLC Siemens S7-1214. Los resultados experimentales muestran que el algoritmo ajusta dinámicamente los parámetros proporcional, integral y derivativo, eliminando el error estacionario y evitando el sobreimpulso durante el control de temperatura. Además, el sistema alcanza la estabilidad después de aproximadamente 2,9 minutos de operación, evidenciando una mejora significativa respecto a los métodos PID convencionales. Estos resultados demuestran que el aprendizaje automático permite incrementar la capacidad adaptativa de los PLC frente a procesos no lineales y variables, superando las limitaciones de los controladores tradicionales.


Otra aplicación ampliamente identificada corresponde al mantenimiento predictivo y la optimización de líneas de manufactura inteligente. En una de las investigaciones [7] se plantea una arquitectura donde el PLC deja de actuar únicamente como controlador lógico para convertirse en un nodo inteligente dentro de un sistema ciberfísico. En esta propuesta, la información proveniente de sensores, dispositivos IIoT y sistemas de gestión es procesada mediante modelos de análisis de datos que permiten realizar diagnósticos en tiempo real, predicción de fallas y ajustes automáticos del proceso productivo. Los resultados indican que esta integración favorece la transición desde estrategias de mantenimiento correctivo hacia enfoques predictivos, incrementando la eficiencia, la flexibilidad y la disponibilidad de las líneas de producción inteligentes.

La literatura también evidencia un creciente interés por ejecutar modelos de Machine Learning directamente cerca del proceso industrial, reduciendo la dependencia de servicios en la nube. En este sentido, en un artículo [6] se presenta una arquitectura basada en Dew Computing que incorpora modelos de aprendizaje automático dentro de los niveles SCADA y PLC para realizar inferencias locales sobre el proceso productivo. Los autores concluyen que esta estrategia disminuye la latencia de procesamiento, mejora la disponibilidad de los datos incluso ante pérdidas

de conectividad y permite actualizar continuamente los modelos predictivos utilizando información histórica sincronizada con la nube. Como resultado, el control industrial adquiere mayor capacidad de respuesta en aplicaciones donde los tiempos de decisión son críticos.

Finalmente, los estudios más recientes evidencian una nueva línea de investigación enfocada en la automatización de la programación de PLC mediante modelos de lenguaje de gran escala. En un artículo [5] se presenta un asistente inteligente basado en Retrieval-Augmented Generation (RAG) capaz de generar código Structured Text específico para plataformas industriales, incorporando validación automática mediante compilación y retroalimentación iterativa. A diferencia de trabajos anteriores, esta propuesta utiliza bases de conocimiento específicas del fabricante y mecanismos de recuperación de información para producir código compatible con entornos propietarios sin requerir grandes conjuntos de entrenamiento. Los resultados muestran que este tipo de herramientas reduce el tiempo de desarrollo, mejora la calidad del código generado y representa una aplicación emergente de la inteligencia artificial en la ingeniería de automatización industrial.

Figura 3. Aplicaciones encontradas en la literatura.



Nota: Elaborado a partir de la información consultada.

Los estudios analizados (5 artículos de los 29 equivalente al 17 % del total de artículos) muestran que la investigación sobre la optimización de procesos industriales mediante Machine Learning y sistemas PLC se orienta hacia arquitecturas cada vez más distribuidas, donde el PLC conserva las funciones críticas de control en tiempo real, mientras que las tareas de aprendizaje, inferencia compleja o generación de código son ejecutadas en dispositivos edge, plataformas de supervisión o infraestructuras híbridas con soporte en la nube. Algunos trabajos comienzan a explorar alternativas para acercar la inteligencia al entorno de ejecución industrial mediante modelos ligeros, despliegues on-premise y estrategias basadas en Retrieval-Augmented Generation (RAG), con el propósito de reducir la dependencia de servicios externos y responder a los requerimientos de seguridad y confidencialidad del sector industrial. Sin embargo, la literatura revisada evidencia que la ejecución completamente local de modelos de Machine Learning dentro del PLC continúa siendo limitada. La mayoría de las propuestas emplea el controlador como elemento de adquisición de datos y ejecución del control, mientras que el procesamiento inteligente permanece en servidores externos, aplicaciones desarrolladas en Python o plataformas edge. Asimismo, ninguno de los trabajos analizados aborda de manera explícita la incorporación de técnicas de Inteligencia

Artificial Explicable (XAI), por lo que persiste un vacío relacionado con el desarrollo de modelos interpretables, ligeros y compatibles con las restricciones de procesamiento, memoria y determinismo propias de los PLC industriales. Esta brecha coincide con el vacío de investigación identificado en el presente estudio sobre la necesidad de avanzar hacia soluciones que permitan una mayor autonomía de los controladores mediante la ejecución local y segura de modelos de Machine Learning.

Machine Learning para el monitoreo y supervisión de sistemas PLC

El análisis de los artículos seleccionados evidencia que una de las principales líneas de aplicación del Machine Learning en sistemas PLC se orienta al monitoreo continuo, la supervisión remota y el análisis inteligente de variables de proceso, aprovechando la integración de tecnologías IIoT, plataformas en la nube y herramientas de análisis de datos. Aunque no todos los estudios implementan modelos de Machine Learning en la etapa experimental, existe consenso en que la disponibilidad de datos generados por los PLC constituye la base para desarrollar sistemas de supervisión capaces de detectar anomalías, anticipar fallas y optimizar la operación de los procesos industriales.

En los estudios analizados, el PLC continúa desempeñando su función principal de adquisición y control de variables industriales, mientras que las capacidades de Machine Learning se incorporan como una capa superior encargada del análisis de la información recolectada. Esta arquitectura distribuida permite mantener la confiabilidad del control en tiempo real y, simultáneamente, habilitar funciones avanzadas de monitoreo y toma de decisiones basadas en datos.

Tabla 2. *Machine Learning para el monitoreo y supervisión de sistemas PLC identificados en la literatura.*

Artículos que lo sustentan	Sistema monitoreado	Variables supervisadas	Tecnología utilizada	Aplicación de ML	Principal aporte
Artículo [14]	Planta solar	Voltaje, corriente, potencia	PLC + SCADA + IoT	Predicción y detección de fallas	Monitoreo remoto
Artículo [10]	PLC industrial	Corriente, temperatura, vibración	ESP32 + MQTT + Node-RED	Base para ML	Diagnóstico en tiempo real
Artículo [11]	Extrusión	Velocidad, temperatura	Siemens S7-1200 + Azure	Analítica predictiva	Supervisión en la nube
Artículo [13]	Producción automática	Tiempos y sensores	PLC + Multiagentes	Detección de anomalías	Procesamiento en el borde
Artículo [12]	Red eléctrica	Señales PLC	Machine Learning	Clasificación de fallas	Monitoreo automático

Nota: Tabla elaborada con la información de las fuentes consultadas.

En un trabajo [14] se muestra esta tendencia mediante un sistema para el monitoreo de plantas solares, donde el PLC y el sistema SCADA recopilan variables eléctricas como voltaje, corriente y generación de energía, mientras que el Machine Learning se emplea para realizar análisis predictivos de la producción energética, identificar posibles defectos en la planta y anticipar

condiciones climáticas que afectan el rendimiento del sistema. Los autores destacan que el uso combinado de IoT y Machine Learning mejora el acceso remoto a la información y proporciona un análisis más detallado que los sistemas tradicionales basados únicamente en PLC/SCADA.


De manera similar, el estudio [10] demuestra que la supervisión de PLC puede fortalecerse mediante arquitecturas IIoT que integran sensores de corriente, temperatura, humedad y vibración con microcontroladores ESP32, protocolos MQTT y plataformas Node-RED. Aunque el trabajo no implementa directamente algoritmos de Machine Learning, establece una infraestructura de adquisición, almacenamiento histórico y visualización en tiempo real que constituye la base para futuras aplicaciones de aprendizaje automático orientadas al diagnóstico predictivo y mantenimiento inteligente. Además, los resultados experimentales muestran respuestas rápidas ante condiciones anormales y una alta precisión en la medición de las variables monitoreadas, aspectos fundamentales para alimentar modelos de Machine Learning con datos confiables.

En la misma dirección, otro estudio [11] desarrollan una arquitectura IIoT para monitorear máquinas de extrusión mediante un PLC Siemens S7-1200, un gateway industrial y almacenamiento en Microsoft Azure. Los autores resaltan que el monitoreo en tiempo real mediante paneles Grafana facilita la supervisión continua del proceso, mientras que el almacenamiento de grandes volúmenes de datos permite incorporar posteriormente algoritmos de Machine Learning para realizar mantenimiento predictivo, detección de anomalías y optimización del proceso productivo. En este estudio se observa que la implementación del Machine Learning depende principalmente de la disponibilidad de datos históricos generados por el sistema de monitoreo basado en PLC.

Por otra parte, en un estudio [13] se presenta un enfoque diferente, donde el procesamiento preliminar de datos y la detección de valores atípicos se ejecutan directamente sobre el PLC utilizando técnicas estadísticas y arquitecturas Multi-Agente. Los autores plantean que este preprocesamiento en el borde (edge computing) reduce el volumen de información enviado a sistemas externos y mejora la calidad de los datos utilizados posteriormente por aplicaciones de Machine Learning. En consecuencia, el PLC deja de ser únicamente un dispositivo de control para convertirse en un nodo inteligente capaz de preparar la información requerida por modelos analíticos más complejos.

En un trabajo [12] se demuestra que las señales obtenidas mediante sistemas PLC de comunicación (Power Line Communication) pueden emplearse como fuente de información para entrenar modelos supervisados de Machine Learning destinados a la detección automática de fallas en cables eléctricos. Los autores proponen una metodología que combina mediciones experimentales y generación sintética de datos para entrenar clasificadores capaces de diferenciar condiciones normales y defectuosas, reduciendo la dependencia de inspecciones manuales y mejorando las capacidades de monitoreo continuo de la infraestructura eléctrica.

Figura 4. *Arquitectura.*



Nota: Elaborado a partir de la información consultada.

Los estudios analizados (5 artículos de los 29 equivalente al 17 % del total de artículos) evidencian que la evolución del monitoreo y supervisión industrial se orienta hacia arquitecturas híbridas donde el PLC continúa desempeñando las funciones de adquisición y control en tiempo real, mientras que el procesamiento analítico y los modelos de Machine Learning se ejecutan principalmente en gateways industriales, plataformas IIoT o infraestructuras en la nube. Aunque algunas investigaciones comienzan a explorar el preprocesamiento de datos y la detección de anomalías directamente sobre el PLC mediante implementaciones compatibles con IEC 61131-3, estas propuestas aún representan casos puntuales y experimentales. En consecuencia, se identifica como principal vacío de la literatura la escasa evidencia sobre la implementación y validación de modelos de Machine Learning ejecutados de manera nativa en los PLC, especialmente en condiciones industriales reales. La mayor parte de los trabajos continúa dependiendo de plataformas externas para realizar el entrenamiento y la inferencia, lo que evidencia la necesidad de investigar arquitecturas que incrementen la capacidad de procesamiento local sin comprometer los requisitos de tiempo real, confiabilidad e interoperabilidad de los sistemas industriales. Esta brecha coincide con el vacío identificado en la presente revisión respecto a la limitada ejecución local de modelos inteligentes frente al predominio de soluciones basadas en edge computing y computación en la nube.

Machine Learning aplicado al mantenimiento predictivo.

El mantenimiento predictivo constituye una de las aplicaciones más consolidadas del Machine Learning dentro de la Industria 4.0. Los estudios revisados coinciden en que la incorporación de algoritmos de aprendizaje automático permite anticipar fallas, optimizar la planificación del mantenimiento y disminuir los tiempos de inactividad mediante el análisis de datos históricos y variables monitoreadas en tiempo real. En lugar de ejecutar mantenimientos programados por intervalos fijos, los modelos predictivos determinan el estado real de los activos industriales y estiman el momento más adecuado para intervenirlos [16][18].

Tabla 3. *Machine Learning aplicado al mantenimiento predictivo identificados en la literatura revisada.*

Artículo	Industria	Variables monitoreadas	Algoritmos ML	Resultados obtenidos
Artículo [16]	Manufactura	Historial de fallas	Random Forest, SVM, XGBoost	Predicción de fallas y reducción de mantenimientos innecesarios
Artículo [17]	Subestaciones eléctricas	DGA, temperatura, humedad	CNN, Random Forest	Disminución de fallas e incremento de la confiabilidad
Artículo [15]	Planta termoeléctrica	Audio	TinyML	Clasificación de fallas en tiempo real
Artículo [18]	Bombas industriales	Vibración, presión, caudal	ML + PLC	Automatización de adquisición de datos para mantenimiento
Artículo [19]	Industria de bombeo	Variables operativas	Lógica difusa + XAI	Predicciones interpretables para los operadores

Nota: La tabla elaborada con la información de las fuentes consultadas.

Una característica común identificada en los artículos es la integración del Machine Learning con tecnologías propias de la Industria 4.0, como sensores IoT, sistemas SCADA, computación en el borde (Edge Computing), plataformas IIoT y dispositivos embebidos. Esta infraestructura permite capturar continuamente variables como vibración, temperatura, humedad, presión, emisiones acústicas, gases disueltos y termografía, generando grandes volúmenes de información que posteriormente son utilizados para entrenar modelos predictivos. En consecuencia, el mantenimiento deja de depender únicamente de inspecciones periódicas para basarse en el monitoreo continuo de las condiciones reales de operación [15][17][18].

Los trabajos revisados muestran igualmente que no existe un único algoritmo de Machine Learning que resulte superior para todas las aplicaciones industriales. La selección del modelo depende principalmente del tipo de datos disponibles, del problema que se desea resolver y de la calidad del conjunto de entrenamiento. En aplicaciones orientadas a clasificación de fallas predominan algoritmos supervisados como Random Forest, Support Vector Machine (SVM), XGBoost y Redes Neuronales Artificiales, mientras que para la detección de anomalías aparecen con frecuencia métodos no supervisados como K-Means y Autoencoders [16][17].

La revisión también permitió identificar diferencias importantes en el desempeño de los modelos. Mientras algunos estudios reportan resultados muy elevados gracias al uso de conjuntos de datos controlados y específicos, otros resaltan que la calidad de la información continúa siendo uno de los principales factores limitantes. Por ejemplo, la implementación de TinyML para clasificación acústica en una planta termoeléctrica alcanzó una precisión del 100 % utilizando características Mel-Filterbank Energy (MFE) y una red neuronal ligera ejecutada directamente sobre dispositivos Edge, demostrando además un bajo consumo de memoria, adecuado para aplicaciones embebidas [15].

El estudio desarrollado sobre activos de manufactura moderna encontró que, aunque Random Forest fue el algoritmo con mejor capacidad de predicción entre los modelos evaluados, su rendimiento se vio limitado por la baja calidad y disponibilidad de los datos históricos. Los autores concluyen que disponer únicamente de registros de fallas resulta insuficiente para construir modelos robustos, siendo necesario incorporar información proveniente de sensores y registros completos de mantenimiento para incrementar la precisión de las predicciones [16].

Otra tendencia relevante encontrada en la revisión corresponde a la creciente incorporación de modelos explicables (Explainable Artificial Intelligence, XAI). Aunque las redes neuronales profundas ofrecen altos niveles de precisión, diversos autores señalan que su naturaleza de "caja negra" dificulta su adopción en entornos industriales donde los operadores necesitan comprender el motivo de cada predicción antes de ejecutar acciones de mantenimiento. En respuesta a esta problemática, se proponen modelos basados en lógica difusa tipo-2 que mantienen un desempeño competitivo frente a técnicas profundas y, simultáneamente, generan reglas interpretables para el personal de mantenimiento. Además, el estudio reporta que el 80,3 % de los especialistas del sector evaluado manifestó estar de acuerdo con las explicaciones proporcionadas por el sistema, fortaleciendo la confianza en las decisiones generadas por la inteligencia artificial [19].

La literatura coincide en que la aplicación del Machine Learning al mantenimiento predictivo genera beneficios tanto técnicos como económicos. En el caso de subestaciones eléctricas, la combinación de algoritmos supervisados, plataformas SCADA, sensores IoT y técnicas de inteligencia artificial explicable permitió disminuir las fallas no programadas hasta en un 25 %, reducir aproximadamente un 20 % los costos correctivos, incrementar la vida útil de los transformadores en un 15 % y mejorar los indicadores de confiabilidad del sistema eléctrico (SAIDI y SAIFI) en valores superiores al 18 %. Estos resultados demuestran que el éxito del mantenimiento predictivo no depende únicamente del algoritmo empleado, sino de la integración entre infraestructura digital, disponibilidad de datos de calidad y modelos capaces de apoyar la toma de decisiones en tiempo real [17].

Figura 6. *Ecosistema del Machine Learning aplicado al mantenimiento predictivo (basado en la literatura revisada).*



Nota: Elaborado a partir de la información consultada.

Los estudios analizados (5 artículos de los 29 equivalente al 17 % del total de artículos) evidencian que el mantenimiento predictivo está evolucionando hacia arquitecturas distribuidas que combinan sensores inteligentes, plataformas IIoT/SCADA y modelos de Machine Learning ejecutados en dispositivos Edge o plataformas externas, reduciendo la latencia y permitiendo un monitoreo más cercano al proceso industrial. Asimismo, se observa una tendencia reciente hacia la incorporación

de técnicas de Inteligencia Artificial Explicable (XAI), orientadas a incrementar la confianza de los operadores y facilitar la interpretación de las predicciones en aplicaciones industriales. No obstante, la revisión también permite identificar un vacío importante en la literatura: aunque varios trabajos acercan el procesamiento al borde mediante Edge-AI y TinyML, ninguno plantea una ejecución nativa de los modelos de Machine Learning dentro del PLC. En la mayoría de los casos, el PLC continúa desempeñando funciones tradicionales de control y adquisición de datos, mientras que la inferencia se realiza en microcontroladores, dispositivos Edge, servidores o plataformas externas. Esta situación evidencia la necesidad de investigar estrategias que permitan integrar capacidades de inferencia directamente en los PLC industriales, disminuyendo la dependencia de infraestructura adicional y favoreciendo sistemas de control más autónomos, robustos y con menor latencia.

Algoritmos de Machine Learning empleados en sistemas PLC

Los estudios analizados muestran que los algoritmos de Machine Learning implementados en entornos industriales con PLC no pertenecen a una única familia de técnicas, sino que responden a diferentes necesidades de automatización, supervisión y mantenimiento. La evidencia recopilada indica que los algoritmos de aprendizaje supervisado continúan siendo los más utilizados cuando existen conjuntos de datos previamente etiquetados, mientras que los métodos de aprendizaje por refuerzo comienzan a incorporarse en problemas de toma de decisiones dinámicas propios de las redes industriales.

Uno de los algoritmos con resultados más consistentes es Random Forest que sirve para automatizar la operación de dispositivos industriales en una arquitectura SCADA basada en RTU [21]. El modelo fue entrenado mediante aprendizaje supervisado utilizando registros de temperatura, humedad ambiental y humedad del suelo, alcanzando precisiones del 98,4 % para el control del sistema de calefacción y 97,6 % para el sistema de ventilación. Los autores destacan que estos resultados permiten reducir la intervención humana, disminuir errores operativos y posibilitar la ejecución del modelo directamente sobre dispositivos de bajo costo como Raspberry Pi, utilizados como alternativa a PLC tradicionales.

Tabla 4. *Algoritmos de Machine Learning empleados en sistemas PLC identificados en la literatura revisada.*

Algoritmo	Aplicación en sistemas PLC/industriales	Artículo de referencia	Principales resultados reportados
Random Forest	Predicción de acciones de control en RTU industriales y mantenimiento predictivo	Artículo [21]	Exactitud superior al 95%; 98,4 % para calefacción y 97,6 % para ventilación.
Redes Neuronales (Keras)	Ejecución de inferencia en PLC mediante Structured Text	Artículo [24]	Permite ejecutar modelos entrenados en tiempo real directamente sobre PLC manteniendo precisión respecto al modelo original.
Multi-Armed Bandit (UCB y variantes)	Selección inteligente de relés en redes PLC	Artículo [23]	Disminución del regret acumulado, mejor probabilidad de selección y reducción del BER frente al UCB convencional.

Algoritmo	Aplicación en sistemas PLC/industriales	Artículo de referencia	Principales resultados reportados
Redes neuronales para mantenimiento predictivo	Diagnóstico de barras rotas en motores de inducción	Artículo [20]	Alta capacidad para clasificar estados de falla utilizando características espectrales previamente seleccionadas.
Algoritmos predictivos basados en ML	Monitoreo energético industrial mediante sensores IoT	Artículo [22]	Identificación temprana de anomalías y optimización del consumo energético mediante mantenimiento predictivo.

Nota: Tabla elaborada con la información de las fuentes consultadas.

Por otra parte, las redes neuronales artificiales aparecen como la técnica predominante cuando el objetivo consiste en realizar tareas de clasificación o aproximación de modelos complejos. En un estudio [24] se desarrolla una biblioteca capaz de convertir modelos entrenados en Keras hacia código Structured Text compatible con PLC industriales. El principal resultado no consiste únicamente en la implementación del algoritmo, sino en demostrar que la inferencia puede ejecutarse dentro del ciclo de tiempo real del PLC manteniendo una precisión equivalente a la obtenida en el entorno de entrenamiento. Este resultado representa un avance importante para la incorporación de inteligencia artificial directamente en el controlador industrial, eliminando la necesidad de servidores externos para ejecutar el modelo.


Los algoritmos de aprendizaje por refuerzo, particularmente el enfoque Multi-Armed Bandit (MAB) y sus variantes Upper Confidence Bound (UCB), representan otra línea de investigación identificada en la revisión. En un estudio [23] se aplicaron este algoritmo para resolver el problema de selección de relés en comunicaciones PLC de banda estrecha afectadas por ruido impulsivo. Los resultados de simulación muestran que las variantes propuestas reducen el regret acumulado, incrementan la probabilidad de seleccionar el relé óptimo y disminuyen la tasa de error de bits (BER) respecto al algoritmo UCB convencional. Aunque esta aplicación se orienta a redes de comunicación PLC y no al control lógico programable, evidencia cómo los métodos de aprendizaje adaptativo comienzan a utilizarse para optimizar decisiones en sistemas industriales donde las condiciones cambian continuamente.

En el ámbito del mantenimiento predictivo, existe un estudio [20] que combinaron técnicas clásicas de procesamiento digital de señales con modelos de Machine Learning para detectar barras rotas en motores de inducción. Antes del entrenamiento, los autores reducen el espacio de características seleccionando únicamente las componentes espectrales donde las fallas producen mayor variación. Esta estrategia permite simplificar el entrenamiento y mejorar la capacidad de clasificación del algoritmo, demostrando que la calidad de las variables de entrada resulta tan importante como el algoritmo empleado.

Un estudio [22] muestra una tendencia diferente, donde los algoritmos predictivos son integrados con redes de sensores IoT para supervisar procesos industriales desde una perspectiva energética. Aunque el trabajo no centra su análisis en un algoritmo específico, evidencia que las técnicas de Machine Learning permiten detectar anomalías, anticipar fallos y optimizar el consumo energético mediante el análisis continuo de datos provenientes de sensores distribuidos. Esto confirma que el

valor del Machine Learning dentro de los sistemas industriales depende de su integración con la infraestructura de adquisición de datos y no únicamente del modelo predictivo utilizado.

Figura 7. Clasificación de los algoritmos de Machine Learning empleados en sistemas PLC e IoT industrial (basado en la literatura revisada).



Nota: Elaborado a partir de la información consultada.

Los estudios analizados (5 artículos de los 29 equivalente al 17 % del total de artículos) evidencian una evolución desde arquitecturas donde el Machine Learning se ejecuta en plataformas externas hacia soluciones que buscan acercar la inteligencia al nivel del control industrial. Mientras algunos trabajos mantienen el procesamiento en dispositivos edge o sistemas IoT conectados al PLC, investigaciones más recientes, como RTNNigen, avanzan hacia la ejecución directa de modelos de aprendizaje automático dentro del propio PLC mediante la conversión de redes neuronales a Structured Text, preservando los requisitos de tiempo real. Asimismo, se observa un creciente interés por algoritmos capaces de tomar decisiones adaptativas en línea, como los enfoques basados en aprendizaje por refuerzo. Sin embargo, la literatura aún presenta un vacío importante: la mayoría de las propuestas continúan dependiendo de hardware externo, plataformas edge o procesos de entrenamiento fuera del PLC, siendo todavía escasos los trabajos que implementan modelos de Machine Learning completamente integrados en controladores industriales comerciales, con evaluación en escenarios reales de operación, interoperabilidad y mantenimiento del modelo durante su ciclo de vida. Este vacío respalda la necesidad de seguir investigando

estrategias que permitan una ejecución local eficiente del Machine Learning directamente en los PLC, reduciendo la dependencia de plataformas externas.

Beneficios obtenidos mediante la incorporación de Machine Learning en sistemas PLC

Los estudios analizados evidencian que la incorporación de algoritmos de Machine Learning en sistemas de automatización industrial basados en PLC aporta beneficios significativos en términos de optimización del control, precisión en la predicción de variables, eficiencia energética, diagnóstico de fallas y soporte a la toma de decisiones. Aunque cada investigación aborda aplicaciones diferentes, todas coinciden en que el aprendizaje automático permite aprovechar los datos históricos generados por los sistemas de control para desarrollar modelos predictivos que complementan el funcionamiento convencional de los PLC.

Uno de los beneficios más reportados corresponde a la mejora en la capacidad predictiva de los procesos industriales. El estudio desarrollado en una planta petroquímica demuestra que los modelos de Machine Learning permiten representar el comportamiento dinámico del proceso sin necesidad de construir modelos fenomenológicos complejos. La comparación entre regresión lineal, regresión no lineal y XGBoost mostró que este último obtuvo el mejor desempeño predictivo, alcanzando un coeficiente promedio de determinación (R^2) de 0,60 durante la validación cruzada, superando ampliamente a los demás modelos. Los autores concluyen que esta capacidad favorece la implementación de estrategias de control predictivo y facilita la optimización de procesos industriales mediante modelos basados en datos [27].

Tabla 5. *Beneficios obtenidos mediante la incorporación de Machine Learning en sistemas PLC identificados en la literatura revisada.*

Beneficio identificado	Evidencia encontrada	Artículo de soporte
Mayor precisión en la predicción de variables del proceso	XGBoost obtuvo el mayor desempeño predictivo (R^2 promedio = 0,60).	Artículo [27]
Optimización del control predictivo	Los modelos permiten representar procesos complejos sin modelos fenomenológicos y facilitan la implementación de MPC.	Artículo [27]
Inferencia de variables en tiempo real	Modelos inferenciales mejoran el monitoreo de viscosidad y apoyan el control en línea.	Artículo [26]
Reducción del consumo energético	Ahorro estimado de 21.249,15 kWh/año y error de predicción inferior al 5 %.	Artículo [28]
Mejor diagnóstico de fallas	Reducción del número de variables manteniendo la capacidad de clasificación mediante CNN y selección automática de variables.	Artículo [25]
Menor complejidad computacional	Selección automática de variables relevantes disminuyendo el procesamiento requerido.	Artículo [25]
Mejor aprovechamiento de datos históricos	Uso de datos provenientes de historiadores industriales y SCADA para construir modelos predictivos.	Artículo [26]


Nota: Tabla elaborada con la información de las fuentes consultadas.

Otro beneficio identificado corresponde a la optimización del control de procesos mediante inferencias en tiempo real. En el trabajo desarrollado para el control de viscosidad en mezclas de fuel oil, los investigadores implementaron un sistema inferencial que integra modelos de Machine Learning dentro de la capa de control industrial, permitiendo estimar continuamente una variable cuya medición directa resulta costosa y lenta. Aunque durante el entrenamiento algoritmos como Random Forest y Gradient Boosting presentaron menores errores, la evaluación sobre datos no utilizados evidenció que el modelo Log-Linear ofrecía un mejor equilibrio entre precisión, robustez y facilidad de implementación industrial, mientras que la red neuronal obtuvo el menor error de prueba ($ASE = 3,9$). Este resultado demuestra que la incorporación de Machine Learning en sistemas PLC no solo mejora la calidad de las estimaciones, sino que también permite seleccionar modelos considerando criterios de mantenibilidad y confiabilidad operacional [26].

La literatura evidencia beneficios relacionados con la eficiencia energética y la reducción de costos operativos. La investigación realizada sobre sistemas de bombeo industriales combinó variadores de frecuencia con redes neuronales LSTM para proyectar el consumo energético futuro. Los resultados mostraron que el error de predicción disminuyó desde valores cercanos al 49 % utilizando métodos tradicionales hasta aproximadamente el 2,41 %, permitiendo estimar con mayor precisión el ahorro energético y el retorno de la inversión. Adicionalmente, el modelo permitió proyectar un ahorro anual estimado de 21.249,15 kWh y un período de recuperación de la inversión cercano a 1,84 años, evidenciando que el uso conjunto de PLC, variadores de frecuencia y Machine Learning mejora significativamente la eficiencia del proceso industrial [28]. En cuanto al monitoreo y diagnóstico de fallas, los estudios muestran que los algoritmos de aprendizaje automático incrementan la capacidad de detectar condiciones anormales incluso cuando no se dispone de todos los sensores del proceso. La propuesta basada en agrupamiento de variables, selección automática mediante LASSO y Elastic Net, y clasificación mediante redes convolucionales (CNN), logró reducir el número de variables necesarias para identificar fallas manteniendo un alto desempeño en la clasificación. Este enfoque disminuye la complejidad computacional, facilita la implementación en procesos industriales de gran escala y aumenta la robustez frente a fallas o pérdida de mediciones, características especialmente relevantes para sistemas de control industrial supervisados mediante PLC [25].

Los artículos coinciden en señalar que el Machine Learning mejora el aprovechamiento de la información histórica almacenada por los sistemas de automatización. Los modelos basados en datos eliminan la necesidad de conocer completamente la dinámica física del proceso, permitiendo construir modelos predictivos a partir de variables registradas por historiadores industriales y sistemas SCADA. Esta característica reduce la complejidad del desarrollo de aplicaciones avanzadas y favorece la incorporación de funciones inteligentes dentro de arquitecturas de automatización existentes [26], [27].

Figura 8. *Beneficios obtenidos mediante la incorporación de Machine Learning en sistemas PLC identificados en la literatura revisada.*



Nota: Elaborado a partir de la información consultada.

Los estudios analizados (5 artículos de los 29 equivalente al 17 % del total de artículos) evidencian una tendencia hacia la incorporación de modelos de Machine Learning cada vez más robustos para el monitoreo y la supervisión de procesos industriales, priorizando el procesamiento de datos históricos provenientes de historiadores industriales, la reducción de variables mediante técnicas de selección de características y el desarrollo de modelos inferenciales capaces de mejorar la detección de fallas y la predicción de variables críticas del proceso. Asimismo, se observa un interés creciente por integrar estos modelos dentro de las arquitecturas de control industrial para apoyar la toma de decisiones operativas; sin embargo, la mayor parte de las implementaciones continúan ejecutándose sobre plataformas computacionales externas o redes de control, utilizando al PLC principalmente como fuente de adquisición de datos y ejecución del control convencional. En este contexto, se identifica como principal vacío la escasa investigación orientada a la ejecución local de modelos de *Machine Learning* directamente en controladores lógicos programables, así como la limitada evaluación de sus restricciones computacionales, requisitos de tiempo real e integración con los estándares propios de la automatización industrial. Este vacío respalda la necesidad de continuar investigando estrategias que permitan acercar las capacidades de inteligencia artificial al nivel del PLC, reduciendo la dependencia de plataformas externas y favoreciendo soluciones más integradas para la Industria 4.0.

Discusión y conclusiones

La presente revisión sistemática permitió analizar el uso del Machine Learning como herramienta de optimización en sistemas PLC para procesos industriales inteligentes, evidenciando que esta integración constituye una de las principales tendencias dentro de la evolución de la automatización industrial y la Industria 4.0. Los estudios analizados muestran que el Machine Learning amplía las capacidades tradicionales de los PLC al incorporar funciones de optimización del control, monitoreo inteligente, mantenimiento predictivo, análisis de datos y asistencia a la programación industrial, favoreciendo procesos más eficientes, adaptativos y orientados a la toma de decisiones basada en datos.

De manera global, la literatura evidencia una tendencia clara hacia arquitecturas distribuidas e híbridas, donde el PLC mantiene las funciones críticas de control en tiempo real, mientras que el entrenamiento y la inferencia de los modelos de Machine Learning se ejecutan principalmente en

plataformas Edge Computing, dispositivos IIoT, servidores industriales o infraestructuras en la nube. Asimismo, se observa un interés creciente por desarrollar modelos ligeros, incorporar técnicas de Inteligencia Artificial Explicable (XAI) y automatizar tareas de ingeniería mediante modelos de lenguaje de gran escala, buscando incrementar la confianza de los operadores y reducir los tiempos de desarrollo de aplicaciones industriales.

La revisión también permitió identificar que la incorporación del Machine Learning aporta beneficios importantes para los sistemas industriales, entre ellos una mayor precisión en el control de procesos, optimización del mantenimiento predictivo, reducción del consumo energético, mejora en la detección de fallas, incremento de la disponibilidad de los sistemas y fortalecimiento de la toma de decisiones mediante el análisis de información histórica y datos adquiridos en tiempo real. Estos beneficios dependen no solamente del algoritmo utilizado, sino también de la calidad de los datos disponibles y de la adecuada integración entre PLC, sensores, plataformas IIoT y sistemas SCADA.

El principal vacío identificado de manera consistente en todas las categorías analizadas corresponde a la limitada implementación de modelos de Machine Learning ejecutados de forma nativa dentro de los PLC industriales. Aunque la literatura presenta avances importantes en arquitecturas Edge Computing, Dew Computing, TinyML y soluciones híbridas, la mayor parte de las investigaciones continúa utilizando el PLC como dispositivo de adquisición de datos y ejecución del control convencional, mientras que el procesamiento inteligente permanece en plataformas externas. Además, todavía son escasos los estudios que evalúan la ejecución local de modelos considerando las restricciones de procesamiento, memoria, determinismo e interoperabilidad propias de los controladores industriales, así como su validación en escenarios reales de operación.

Como limitación de la presente revisión, debe señalarse que la búsqueda bibliográfica se realizó únicamente en las bases de datos IEEE Xplore y ScienceDirect, considerando publicaciones entre 2020 y 2026. Si bien estas bases reúnen una parte importante de la producción científica relacionada con automatización industrial y Machine Learning, es posible que investigaciones relevantes indexadas en otras fuentes no hayan sido incluidas, lo cual puede restringir el alcance de los resultados obtenidos.

Finalmente, se recomienda que futuras investigaciones se orienten al desarrollo de modelos de Machine Learning ligeros, interpretables y compatibles con los requisitos de tiempo real de los PLC, así como a su implementación y validación en entornos industriales reales. Asimismo, resulta pertinente profundizar en la integración de técnicas de Inteligencia Artificial Explicable, estrategias de aprendizaje en el borde y mecanismos que permitan incrementar la autonomía de los controladores sin comprometer la seguridad, la confiabilidad y la interoperabilidad de los sistemas industriales. Estos avances contribuirán a consolidar la incorporación del Machine Learning como una tecnología clave para la evolución de los PLC dentro de la Industria 4.0.

Referencias

- [1] F. Bachinger, J. Zenisek, and M. Affenzeller, “Automated machine learning for industrial applications—challenges and opportunities,” *Procedia Computer Science*, vol. 232, pp. 1701–1710, 2024.

- [2] R. Rai, M. K. Tiwari, D. Ivanov, and A. Dolgui, "Machine learning in manufacturing and Industry 4.0 applications," *International Journal of Production Research*, vol. 59, no. 16, pp. 4773–4778, 2021.
- [3] V. S. Gurav, A. Gugnani, Y. R. Meena, V. Marathe, S. A. A. Vijay, and S. Nanda, "The impact of industrial automation on the manufacturing industry in the era of Industry 4.0," in *Proc. 2024 15th International Conference on Computing Communication and Networking Technologies (ICCCNT)*, Kamand, India, 2024, pp. 1–6.
- [4] D. Zamora-Arranz, P. Garcia-Bringas, J. J. Gude, and J. Del Ser, "Leveraging programmable logic controllers for machine learning applications in industrial setups," *Results in Engineering*, Art. no. 110194, 2026.
- [5] J. Kersting, M. Rummel, and G. Benndorf, "Vendor-aware industrial agents: RAG-enhanced LLMs for secure on-premise PLC code generation," in *Proc. 2026 IEEE International Conference on Industrial Technology (ICIT)*, Mar. 2026, pp. 1–7.
- [6] M. Sverko, N. Tankovic, and D. Etinger, "Dew computing in industrial automation: applying machine learning for process control," in *Proc. 2021 IEEE 45th Annual Computers, Software, and Applications Conference (COMPSAC)*, Jul. 2021, pp. 1789–1794.
- [7] X. Li, "Research on the system design and application strategy of intelligent manufacturing production line based on PLC," in *Proc. 2025 International Conference on Computing, Robotics and System Sciences (ICRSS)*, Nov. 2025, pp. 92–97.
- [8] X. Zhang, "Design and application of PLC control system based on neural network," *Procedia Computer Science*, vol. 261, pp. 1005–1011, 2025.
- [9] L. Scislo, J. Szlaga, and M. Rażny, "Intelligent voice control in industrial automation: Python-mediated PLC-HMI integration for conveyor systems and operational resilience," in *Proc. 2025 IEEE 13th International Conference on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications (IDAACS)*, Sep. 2025, pp. 827–832.
- [10] S. Pawar, P. Kanjalkar, A. Londhe, V. Gite, and S. Wabale, "PLC diagnosis and monitoring system," in *Proc. 2025 International Conference on Inventive Computation Technologies (ICICT)*, Kirtipur, Nepal, 2025, pp. 1481–1488.
- [11] M. Cardona, B. Vásquez-Pineda, R. Torres, and J. Barahona, "Real-time IIoT cloud-based monitoring and analytics for extrusion and cooling systems," in *Proc. 2025 IEEE 43rd Central America and Panama Convention (CONCAPAN XLIII)*, Nov. 2025, pp. 1–5.
- [12] Y. Huo, G. Prasad, L. Lampe, V. C. Leung, R. Vijay, and T. V. Prabhakar, "Measurement aided training of machine learning techniques for fault detection using PLC signals," in *Proc. 2021 IEEE International Symposium on Power Line Communications and its Applications (ISPLC)*, Oct. 2021, pp. 78–83.
- [13] C. Wagner, D. Hujo-Lauer, and B. Vogel-Heuser, "Plug-and-play PLC-based monitoring and outlier detection for inline production systems via a generalized multi-agent approach," in *Proc. 2025 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, Oct. 2025, pp. 5565–5572.
- [14] A. Siddiqua, A. Anjum, S. Kondapalli, and C. Kaur, "Regulating and monitoring IoT controlled solar power plant by ML," in *Proc. 2023 International Conference on Computer Communication and Informatics (ICCCI)*, Jan. 2023, pp. 1–4.

- [15] P. D. Putra, “Implementation of audio classification using Tiny Machine Learning for predictive maintenance in Muara Karang Power Plant,” in *Proc. 2024 International Conference on Technology and Policy in Energy and Electric Power (ICTPEP)*, Sep. 2024, pp. 79–84.
- [16] A. Shaala, D. Baglee, and D. Dixon, “Machine learning model for predictive maintenance of modern manufacturing assets,” in *Proc. 2024 29th International Conference on Automation and Computing (ICAC)*, Aug. 2024, pp. 1–6.
- [17] M. D. F. Cueva, F. S. Vila, and J. M. F. Camayo, “Application of machine learning in the predictive maintenance of distribution substations aimed at reducing failures,” in *Proc. 2026 16th International Conference on Power, Energy, and Electrical Engineering (CPEEE)*, Mar. 2026, pp. 252–257.
- [18] G. Azinheira, S. Brito, J. Semião, and N. Sousa, “A laboratory fault-injection automation system for industrial pumping predictive maintenance,” in *Proc. 2025 IEEE 8th International Conference on Industrial Cyber-Physical Systems (ICPS)*, May 2025, pp. 1–6.
- [19] S. J. Upasane, H. Hagra, M. H. Anisi, S. Savill, I. Taylor, and K. Manousakis, “A type-2 fuzzy-based explainable AI system for predictive maintenance within the water pumping industry,” *IEEE Transactions on Artificial Intelligence*, vol. 5, no. 2, pp. 490–504, 2023.
- [20] K. Kudelina, H. A. Raja, V. Rjabtšikov, M. U. Naseer, T. Vaimann, and A. Kallaste, “Signal processing and machine learning techniques for predictive maintenance of rotor bars in induction machine,” in *Proc. 2023 International Conference on Electrical Drives and Power Electronics (EDPE)*, Sep. 2023, pp. 1–7.
- [21] A. Hercegovac, E. Babovic, and S. Nogo, “Improving the concept of low cost PC-to-PC industrial IoT systems using artificial intelligence algorithms on credit card size computers,” in *Proc. 2024 23rd International Symposium INFOTEH-JAHORINA (INFOTEH)*, Mar. 2024, pp. 1–6.
- [22] G. Agarwal, A. Kaushik, M. K. Singh, V. Bhargava, and S. Bansal, “Energy-efficient monitoring of industrial processes using IoT sensors and predictive algorithms,” in *Proc. 2025 3rd International Conference on Disruptive Technologies (ICDT)*, Mar. 2025, pp. 1573–1577.
- [23] W. B. Sghaier, H. Gassara, F. Rouissi, and F. Tlili, “Enhanced MAB algorithm for cooperative communication in narrowband PLC channel corrupted by impulsive noise,” in *Proc. 2023 International Wireless Communications and Mobile Computing (IWCMC)*, Jun. 2023, pp. 18–23.
- [24] C. Hinze, Z. Zhou, H. Xu, A. Lechler, and A. Verl, “RTNNIgen—an open-source PLC library and Python generator converting Keras models to realtime capable Structured Text,” in *Proc. IECON 2024–50th Annual Conference of the IEEE Industrial Electronics Society*, Nov. 2024, pp. 1–7.
- [25] N. Yassaie, S. Gargoum, and A. W. Al-Dabbagh, “Data-driven fault classification in large-scale industrial processes using reduced number of process variables,” *IEEE Transactions on Automation Science and Engineering*, vol. 21, no. 4, pp. 5749–5765, 2023.
- [26] A. Bakhurji, A. Filali, H. Alghamdi, S. Choi, R. Patwardhan, K. M. Patel, and A. A. Bahamdan, “Deployment of a fuel oil blending viscosity inferential—a comparison of

- conventional and machine learning models,” in *Proc. 2022 IEEE International Symposium on Advanced Control of Industrial Processes (AdCONIP)*, Aug. 2022, pp. 276–282.
- [27] C. A. Vieira, P. V. dos Santos, H. O. dos Santos Lima, J. J. de Lima, and M. Scoczynski, “Application of machine learning models for predicting variables of industrial processes: A case study in a petrochemical industry,” in *Proc. 2024 IEEE Latin American Conference on Computational Intelligence (LA-CCI)*, Nov. 2024, pp. 1–6.
- [28] M. D. Osorio, V. M. Baca, and L. Loo, “Optimization of energy savings and economic feasibility in industrial processes using frequency inverters, centrifugal pumps, and machine learning,” in *Proc. 2024 IEEE International Humanitarian Technologies Conference (IHTC)*, Nov. 2024, pp. 1–7.
- [29] E. Solowjow, I. Ugalde, Y. Shahapurkar, J. Aparicio, J. Mahler, V. Satish, *et al.*, “Industrial robot grasping with deep learning using a programmable logic controller (PLC),” in *Proc. 2020 IEEE 16th International Conference on Automation Science and Engineering (CASE)*, Aug. 2020, pp. 97–103.
- [30] Z. Xu, I. Petrunin, A. Tsourdos, R. Grech, P. Peltola, and S. Tiwari, “Combination and selection of machine learning algorithms in GNSS architecture design for concurrent executions with HIL testing,” in *Proc. 2023 IEEE/AIAA 42nd Digital Avionics Systems Conference (DASC)*, Oct. 2023, pp. 1–9.