



Universidad del Desarrollo
Facultad de Ingeniería

GESTIÓN DEL MANTENIMIENTO DE ACTIVOS CON USO DE
TECNOLOGÍAS DE INDUSTRIA 4.0

JOSÉ ALFREDO JIMÉNEZ GATICA

PROFESOR(ES) GUÍA: PAUL BOSCH, PhD (UDD)

PROYECTO DE GRADO PRESENTADO A LA FACULTAD DE INGENIERÍA DE LA
UNIVERSIDAD DEL DESARROLLO PARA OPTAR AL GRADO ACADÉMICO DE MAGÍSTER
EN INGENIERIA INDUSTRIAL Y SISTEMAS

SANTIAGO – CHILE
2025



Universidad del Desarrollo
Facultad de Ingeniería

**GESTION DEL MANTENIMIENTO DE ACTIVOS CON USO DE TECNOLOGIAS DE
INDUSTRIA 4.0**

Por: **JOSÉ ALFREDO JIMÉNEZ GATICA**

Proyecto de Grado presentado a la Comisión integrada por los profesores:

PROFESORES GUÍA: Paul Bosch, PhD (UDD)

PROFESOR INTEGRANTE 1: Lorenzo Reyes, PhD

PROFESOR INTEGRANTE 2: Cesar Sandoval, PhD

Para completar las exigencias del Grado de Magíster en Ciencias de la Ingeniería en
la Universidad del Desarrollo de Chile

Octubre, 2025

Santiago, Chile

DECLARACIÓN DE ORIGINALIDAD

Por medio de la presente, declaro que el trabajo titulado **GESTIÓN DEL MANTENIMIENTO DE ACTIVOS CON USO DE TECNOLOGÍAS DE INDUSTRIA 4.0**, que presento a la Universidad del Desarrollo de Chile, es de mi autoría y no ha sido publicado previamente, ni está siendo considerado para publicación bajo otra filiación. En igual sentido, declaro que el trabajo de tesis y su contenido, son originales y que todos los datos y referencias a trabajos ya publicados con anterioridad han sido debidamente identificados, referenciados o citados en el documento, y que estas citas han sido incluidas en las referencias bibliográficas. Afirmo, asimismo, que los materiales presentados no se encuentran protegidos por derechos de autor; y en caso de que así lo estuvieran, me hago responsable de cualquier litigio o reclamo relacionado con la violación de derechos de propiedad intelectual, exonerando de toda responsabilidad a la Universidad del Desarrollo de Chile.

Finalmente, me comprometo a no someter este trabajo, a consideración en ninguna revista o congreso para publicación sin contar con la aprobación y haber pasado el debido proceso de revisión en Universidad del Desarrollo. En caso de que un artículo sea aprobado para su publicación, autorizo a la Universidad del Desarrollo a incluir dicho artículo en sus revistas, y a reproducirlo, editarlo, distribuirlo, exhibirlo y comunicarlo en el país y en el extranjero, por medios impresos, electrónicos, Internet o cualquier otro medio, para propósitos científicos y sin fines de lucro.

A handwritten signature in blue ink, consisting of several overlapping loops and lines, positioned above the name of the author.

JOSÉ ALFREDO JIMÉNEZ GATICA

Firma

*Dedicado a Francisco:
En él encontré la amistad incondicional,
y es digno de mi admiración porque,
aun en la dificultad, no se dio por vencido
en su sueño de ser ingeniero mecánico.
Este logro es tan tuyo como mío.
Siempre te recordaré.*

AGRADECIMIENTOS

En las siguientes líneas deseo expresar mis agradecimientos a todas las personas que de una u otra manera me alentaron y apoyaron en la decisión de ingresar al programa de Magister en Ingeniería Industrial y Sistemas. También a aquellos que en el trabajo me cubrieron de manera desinteresada para poder cumplir mi sueño de ostentar un postgrado.

Individualizando a las personas, en primera instancia debo agradecer al director del programa, nuestro profesor Héctor Valdés, PhD, que me entrevistó y aceptó en el programa. Él fue también quien me alentó cuando mis circunstancias personales y laborales se volvieron cuesta arriba, y me dio las instancias para poder cumplir con el calendario académico. También agradezco su guía en esta etapa final de gestación del trabajo de grado. Probablemente sin su empujón no hubiera logrado ver la luz al final del camino.

También quisiera agradecer a mis compañeros de estudio en el MIIS, que son Daniel Vidal, Pablo Ramos y Matías Guerrero, que, desde el principio, en el primer trabajo, si no mal recuerdo del ramo gestión de operaciones, iniciamos esta aventura, apoyándonos en largas jornadas de estudio y compartiendo experiencias de vida y laborales. Amigos, en este tiempo algunos hemos quedado sin empleo, otros se han cambiado incluso uno de nosotros fue padre, es precioso ver en poco tiempo como nuestras vidas cambian. Hemos pasado experiencias vividas a pesar de la lejanía y de no conocernos personalmente.

A continuación, quiero agradecer a mis padres, Magali y Polo, quienes sin dudar me volvieron a recibir en su hogar luego de mi desvinculación laboral. Independiente de mi objetivo académico, me han alentado y atendido en este proceso que, a pesar de difícil por las circunstancias, son los mismos que me permiten compartir nuevamente con ustedes.

También quisiera agradecer a mis sobrinos Luciano y Violeta, que, con su compañía, me han llenado de amor, y dejando hermosos recuerdos que cuando sean más grandes les contare todas las travesuras que hacían a mi alrededor. Volver a vivir cerca de ustedes me ha permitido conocerlos más y ser parte de sus vidas

Quiero agradecer a mi hermana Rocío por acompañarme en este proceso, por permitirte contarte lo que he estado haciendo estos últimos meses. Siempre ha sido placentero el tipo de conversaciones que mantenemos para comprender que hacemos en nuestras vidas que son distintas.

GESTIÓN DEL MANTENIMIENTO DE ACTIVOS CON USO DE TECNOLOGÍAS DE INDUSTRIA 4.0

JOSÉ ALFREDO JIMÉNEZ GATICA

Bajo la supervisión del profesor Paul Bosch (PhD) en la Universidad del Desarrollo de
Chile

Resumen

Este trabajo expone un estudio de metaanálisis que incluye publicaciones de diferentes países y continentes para la evaluación y detección de estrategias y formas de abordar el mantenimiento de activos individuales y sistemas. El objetivo de esta investigación es determinar las principales tendencias en la gestión de mantenimiento en el marco de Industria 4.0, para su aplicación en organizaciones. **Para lograrlo se propuso un** paradigma postpositivista y enfoque mixto. Este metaanálisis transversal analiza 50 artículos entre 2014 y 2025 de seis continentes. Los criterios de inclusión fueron texto completo en inglés/español y estudios de mantenimiento con Industria 4.0. Como instrumentos se utilizaron ficha de extracción, marco de codificación y planilla Excel. Variables: año, área, metodología, sujetos, filiación y continente. Análisis de contenido y síntesis descriptiva-comparativa, con cálculo de medidas de asociación y tablas de resumen. Los **principales resultados** muestran que el mantenimiento predictivo en conjunto con el mantenimiento basado en condición, habilitado por el internet de cosas, analítica y gemelos digitales, reduce fallos y costos, mejora disponibilidad y la eficacia global de los equipos, y fortalece decisiones basadas en datos en sectores ferroviario, manufactura, minería, automotriz y edificación industrial. Modelos híbridos machine learning – deep learning estiman la vida útil remanente de activos con precisión. El estudio muestra que los modelos de mantenimiento con tecnologías de Industria 4.0 reconfiguran la función hacia enfoques predictivos y prescriptivos, reduciendo fallas y costos, mejorando la disponibilidad y la eficacia de los activos, tomando decisiones basadas en datos. Lo habilitan sensores, internet de las cosas y gemelos digitales. Persisten brechas de interoperabilidad, calidad y gobierno de datos, ciberseguridad y operación de modelos. Claves son calidad e interoperabilidad de datos, cobertura sensorica borde-nube e integración de sistemas de gestión de mantenimiento y de gestión corporativa.

Palabras clave: Metaanálisis, Mantenimiento predictivo, interoperabilidad, Gobernanza de datos, arquitectura borde-nube.

HIGHLIGHTS

GESTIÓN DEL MANTENIMIENTO DE ACTIVOS CON USO DE TECNOLOGÍAS DE INDUSTRIA 4.0

JOSÉ ALFREDO JIMÉNEZ GATICA

- Determina tendencias de mantenimiento e industria 4.0 cotejando enfoques y regiones
- Propone metaanálisis global sobre mantenimiento 4.0 en inglés y español
- Analiza 50 artículos entre 2014 y 2025 con uso de ficha de extracción de variables
- Mantenimiento predictivo basado en condición y tecnologías 4.0 mejora OEE y costos
- Encamina a predicción persistiendo brechas de calidad e interoperabilidad de datos

Tabla de contenido

1	Introducción.....	8
1.1	Gestión de mantenimiento con uso de tecnologías de industria 4.0: Novedad, propuesta y contribución	11
1.2	Objetivos de la investigación.....	11
2	Metodología	12
3	Resultados	14
3.1	Análisis de resultados	17
3.2	Discusión de Resultados	20
4	Conclusiones	25
4.1	Trabajos futuros	26
5	Referencias.....	27
6	Anexo 1: Revisión de plagio	32

1 Introducción

A lo largo de la evolución industrial, el mantenimiento pasó de una práctica reactiva centrada en reparar averías a un sistema de gestión que anticipa, prioriza y aprende, directamente vinculado con la confiabilidad, la disponibilidad y la seguridad del proceso productivo. Ese tránsito reconfiguró su estatus, dejando de operar como silo funcional para convertirse en capacidad estratégica que orquesta recursos, riesgos y continuidad operativa junto con producción, logística y calidad. La integración de políticas, datos y decisiones a distintos niveles tanto equipo, línea, planta y gobierno corporativo, permite alinear objetivos técnicos y económicos, optimizando costos del ciclo de vida y desempeño global. Esta maduración está ampliamente documentada por revisiones que conectan gestión de mantenimiento, confiabilidad y operaciones en entornos de transformación digital (Bokrantz et al., 2020; Mantravadi & Møller, 2019).

En ese contexto, la digitalización contemporánea potencia la gestión al habilitar flujos de información en tiempo real, modelos analíticos que explican y predicen el deterioro, y espacios virtuales para ensayar decisiones antes de ejecutarlas. Sin describir tecnologías en detalle, su efecto conjunto se traduce en decisiones basadas en condición y riesgo, sincronizadas con la planificación de producción y el abastecimiento de repuestos; además, consolida una cultura de mejora continua sustentada en evidencia y métricas comparables (disponibilidad, tiempo medio para reparar, efectividad global del equipo). La literatura reciente destaca que este enfoque “inteligente” exige estrategia, gobierno de datos y articulación organizacional para capturar valor sostenido y escalar más allá de pilotos locales (Carvalho et al., 2019; Werbińska-Wojciechowska & Winiarska, 2023).

Industria 4.0

La noción de Industria 4.0 designa la cuarta gran etapa del desarrollo industrial, tras la mecanización por vapor y agua (1ª), la producción en masa electrificada (2ª) y la automatización computarizada (PLC) (3ª). La cuarta revolución industrial se caracteriza por la incorporación de tecnologías digitales que habilitan fábricas inteligentes con mayores niveles de calidad, confiabilidad y eficiencia operativa. En este marco, *los sistemas ciberfísicos* (CPS), el *internet de las cosas* (IoT) y la analítica avanzada permiten que máquinas y procesos intercambien información, aprendan de los datos y optimicen decisiones en la producción y el mantenimiento.

Dentro de las principales características arquitectónicas de la industria 4.0 destaca la (i) **interconexión** que se refiere a la capacidad de enlazar, en tiempo real, personas, máquinas, sensores y sistemas a lo largo de la cadena de valor. Esta conectividad asegura visibilidad de extremo a extremo y coordinación ágil de las funciones de operación y mantenimiento. Por otro lado, la (ii) **interoperabilidad**, exige estándares, ontologías y protocolos que permitan que los *sistemas informáticos de gestión de mantenimiento* (CMMS), *software de gestión corporativa* (ERP), *sistemas de ejecución de manufactura* (MES), *sistemas de supervisión, control y adquisición de datos* (SCADA), PLC y activos inteligentes “hablen el mismo idioma”, asegurando que los datos fluyan sin fricciones entre módulos heterogéneos y que los reportes sean consistentes a nivel de equipo, línea, planta y empresa. Otra característica es la (iii) **integración** que opera en tres planos: el vertical (del piso de planta al nivel corporativo), horizontal (entre actores de la cadena de suministro) y extremo a extremo (a lo largo del ciclo de vida del activo). Esta arquitectura posibilita sincronizar planificación, repuestos y recursos con la condición real de los equipos. Por último, la (iv) **descentralización** indica que, en vez de existir un centro único, parte del control de los procesos se transfiere a módulos inteligentes ubicados en distintos puntos de la planta. Estos componentes toman decisiones in situ y se coordinan entre ellos, lo que permite adaptación inmediata y ajustes locales ante cambios operativos. El

resultado es la fábrica inteligente: un sistema socio-técnico interconectado, interoperable e integrado, capaz de adaptarse dinámicamente a perturbaciones y objetivos de negocio (Shaheen y Németh, 2022).

Tecnologías de Industria 4.0

Las tecnologías clave de la Industria 4.0 conforman una arquitectura físico-digital que habilita la fábrica inteligente mediante captura masiva de datos, análisis avanzado y decisiones cercanas al punto de operación. En su base se encuentra el *Internet de las Cosas industrial* (IIoT), que despliega sensorización inteligente tales como vibración, temperatura, imagen, electricidad, y conectividad inalámbrica o cableada para monitorear activos y procesos en tiempo real. La *computación en la nube y en el borde* (cloud/edge) proveen elasticidad y latencia adecuada: el borde filtra y reacciona localmente, mientras la nube integra históricos, modelos y orquestación a escala. Sobre estas capas, la *big data* y *machine learning* (ML) que comprende algoritmos supervisados hasta redes profundas, permiten detectar anomalías, diagnosticar causas probables y estimar *vida útil remanente* (RUL), habilitando mantenimiento predictivo alineado a objetivos de disponibilidad y costo (Pech et al., 2021; Sahli et al., 2021).

Los sistemas ciberfísicos conectan sensores, actuadores y controladores tales como: PLC, *sistemas de control distribuido* (DCS) y control numérico computarizado (CNC), con los niveles de supervisión y gestión (SCADA, MES, CMMS y ERP), cerrando el ciclo de datos desde el piso de planta hasta la planificación táctica y estratégica. Esta integración multinivel sostiene la interconexión de equipos y la interoperabilidad entre plataformas heterogéneas mediante estándares y esquemas conceptuales, lo que facilita trazabilidad, coordinación de tareas y respuesta ágil ante eventos. En paralelo, los gemelos digitales crean réplicas virtuales de líneas y activos que sincronizan datos operativos para simular escenarios, evaluar estrategias y optimizar intervenciones de mantenimiento y producción con menor riesgo y costo (Shaheen & Németh, 2022; Pech et al., 2021).

La robótica avanzada aporta precisión, repetibilidad y seguridad, y se integra con visión por computador y analítica para tareas de montaje, inspección y manipulación en entornos mixtos humano-máquina. La manufactura aditiva (impresión 3D) acelera prototipado y repuestos de baja rotación, reduciendo tiempos de inactividad y dependencia de cadenas logísticas. La *Realidad aumentada/virtual* (AR/VR) potencia la formación, el soporte remoto y la ejecución de procedimientos estandarizados con instrucciones contextuales. Estas tecnologías, coordinadas sobre IIoT, cloud/edge y analítica, materializan la fábrica inteligente: un sistema socio-técnico capaz de auto adaptarse y optimizarse con base en datos (Pech et al., 2021).

En términos de gestión, el CMMS digitaliza órdenes de trabajo, repuestos y costos, mientras que el MES orquesta la ejecución de la producción y el ERP consolida la visión financiera y de recursos. Integrados, estos sistemas permiten que eventos de proceso como, por ejemplo: paradas, calidad, cuellos de botella, alimenten decisiones de mantenimiento basadas en condición y criticidad. A su vez, las acciones de mantenimiento retroalimentan la planificación productiva. Este tránsito desde lo correctivo y preventivo hacia predictivo y prescriptivo se apoya en marcos técnicos y metodológicos del mantenimiento de activos físicos, y enfoques basados en riesgo, ahora ampliados por capacidades digitales y de *inteligencia artificial* IA (Moleda et al., 2017; Sahli et al., 2021).

Finalmente, la ciberseguridad industrial y la gobernanza de datos son factores críticos para escalar: proteger dispositivos, redes y aplicaciones, entendiéndose desde el sensor al cloud, y asegurar calidad y trazabilidad de datos resulta imprescindible para sostener modelos confiables y operaciones resilientes. En conjunto, estas tecnologías y rasgos arquitectónicos (interconexión, interoperabilidad, integración vertical/horizontal y descentralización) explican el salto de desempeño

de Industria 4.0 y su impacto directo en el mantenimiento 4.0 (Shaheen & Németh, 2022; Pech et al., 2021; Moleda et al., 2017; Sahli et al., 2021).

Gestión del mantenimiento de activos

Evolución de las estrategias de mantenimiento

Históricamente, el mantenimiento comenzó como *correctivo* (CM) con un enfoque reactivo, que consiste en intervenir los equipos luego de ocurrir la falla, que si bien exige poca planificación genera interrupciones en el flujo de producción asumiéndose altos costos para las organizaciones. La evolución en la estrategia de mantenimiento nos presenta al *mantenimiento preventivo* (PM) basado en intervalos de tiempo, que se sustenta en inspecciones periódicas de los equipos, que sin embargo provocan interrupciones innecesarias agregando que en el 70% de las veces no se detectan fallas y por lado asumiendo un deterioro homogéneo de los activos no considerando la variabilidad de las condiciones operativas en que están inmersas (Nsor, 2024). Estas estrategias históricamente han sido predominantes, que dependen de la experiencia de los mantenedores y carecen de parámetros estandarizados lo que genera reemplazos de componentes de manera prematura, provocando costos innecesarios (Canizo et al., 2017; Sahli et al., 2021; Taş, 2024).

El *mantenimiento predictivo* (PdM) es una estrategia proactiva que decide intervenir según el estado observable del activo. Se apoya en **monitoreo de condición** tales como: vibración, temperatura, corriente, análisis de aceite; **tendencias**, detección de anomalías, diagnóstico de causas probables, **pronósticos de degradación** y estimación de vida útil remanente. Su objetivo es maximizar disponibilidad y seguridad, reduciendo fallas imprevistas, costos totales y paradas no planificadas mediante decisiones oportunas y basadas en evidencia (Pech et al., 2021; Sahli et al., 2021; Moleda et al., 2023; Shaheen & Németh, 2022).

Metodologías, técnicas y herramientas de gestión del mantenimiento

El portafolio clásico de gestión del mantenimiento combina enfoques estratégicos, metodológicos y herramientas operativas que se articulan desde el nivel del activo hasta la planta. **RCM (Reliability-Centered Maintenance)** define qué tareas realizar y cuándo, partiendo de funciones, modos de falla y consecuencias, para seleccionar entre correctivo, preventivo por tiempo y uso, basado en condición o rediseño. **TPM (Total Productive Maintenance)** extiende el cuidado del equipo a toda la organización mediante mantenimiento autónomo, planificado, mejora enfocada y formación, buscando maximizar *la eficiencia global de los equipos* (OEE) y cero averías, defectos y accidentes. **CBM (Condition-Based Maintenance)** centra las decisiones en variables de condición (vibración, temperatura, aceite, ultrasonido, termografía) con umbrales y tendencias que disparan inspecciones o intervenciones en el punto económicamente óptimo. Para eliminar recurrencias, **RCA (Root Cause Analysis)** estructura la indagación de causas latentes e inmediatas con árbol de fallas, 5 porqués y diagramas causa-efecto. En la fase preventiva, **FMEA/FMECA** identifica modos de falla, efectos y criticidad mediante métodos o matrices severidad-ocurrencia-detectabilidad, para priorizar acciones y barreras de control. A nivel sistémico, **RAMS (Reliability, Availability, Maintainability, Safety)** alinea objetivos y métricas como: *tiempo medio entre fallas* (MTBF), tiempo medio de reparación (MTTR), tasas de falla, *lista acumulada de tareas de mantenimiento sin ejecutar* (backlog), costo del ciclo de vida, con la estrategia operacional. La ejecución y trazabilidad se soportan en **CMMS/ERP** para órdenes, repuestos, costos y planes, mientras **SCADA, PLC, DCS** y **MES** capturan y orquestan datos de operación y producción. En conjunto, estas prácticas proveen un marco robusto para prevenir, detectar y mitigar fallas, optimizar recursos y alinear mantenimiento con la criticidad del proceso; sin embargo, su efectividad depende de la calidad y oportunidad de los datos, la disciplina en la ejecución y la **integración** entre telemetría, gestión y operación, un punto débil frecuente en

arquitecturas convencionales con baja interoperabilidad (Moleda et al., 2023; Pech et al., 2021; Sahli et al., 2021; Shaheen & Németh, 2022;).

Entendida esta realidad, y considerando la revisión bibliográfica presentada, es posible efectuar el siguiente cuestionamiento de contexto: ¿Cuáles son los potenciales efectos de la implementación de modelos de gestión de mantenimiento con uso de tecnologías de industria 4.0?, y cómo difieren por continente, sector productivo y sujeto de estudio?

La identificación y evaluación de los efectos que tienen las tecnologías de la industria 4.0 en el mantenimiento permitirá tener una mejor comprensión del alcance de cada una de ellas, y de cómo se complementan entre sí, para fomentar la interoperabilidad con equipos ya en operación que tienen incorporados sensores y se controlan con PLC.

1.1 Gestión de mantenimiento con uso de tecnologías de industria 4.0: Novedad, propuesta y contribución

Habiendo recorrido las bases teóricas fundamentales para este estudio, cabe mencionar que la principal motivación para realizarlo ha sido el interés de las empresas líderes del país de adoptar herramientas metodológicas de gestión de activos y mantenimiento, en conjunto del uso de tecnologías inteligentes, para mejorar el desempeño operativo de los equipos y de las plantas industriales en general, alineados a un cambio cultural de quienes integran y participan de las organizaciones. Dado lo anterior se propone un estudio de metaanálisis de artículos de revistas científicas, donde se desarrollen modelos de gestión del mantenimiento con uso de tecnologías inteligentes de la industria 4.0, donde estos sean validados empíricamente y/o experimentalmente con datos reales, o que bien solo propongan marcos conceptuales con resultados proyectados. En este sentido este trabajo contribuye al conocimiento y entendimiento de como en otros lugares del globo se ejecuta el mantenimiento, que problemas y dificultades tienen. También que sistemas y ensamblajes tecnológicos se están usando y probando, cuales son su utilidad y efectividad y cuáles son los desafíos y proyecciones en la materia.

1.2 Objetivos de la investigación

Entendido esto, el objetivo de este trabajo es determinar las principales tendencias en la implementación de modelos de gestión del mantenimiento con uso de tecnologías de la industria 4.0, para el establecimiento lineamientos generales para su aplicación en organizaciones.

Los objetivos específicos son:

- **Caracterizar** por región y sector las tecnologías de Industria 4.0 y estrategias de mantenimiento empleadas.
- **Cuantificar** el desempeño de la ejecución de las estrategias de mantenimiento y tecnologías de Industria 4.0.
- **Definir** lineamientos de interoperabilidad, gobierno de datos y ciberseguridad para escalar modelos analíticos y gemelos digitales con integración CMMS-ERP y trazabilidad técnico-económica.

2 Metodología

Se desarrolló un metaanálisis de diseño transversal (Alarcon & Astudillo, 2007; Pech et al., 2021) que examinó 50 artículos originales de ingeniería publicados entre enero de 2014 y julio de 2025 en revistas internacionales, cuyos continentes de procedencia son: Asia, Europa, Norteamérica, África, Sudamérica y Oceanía (ver tabla 1). La elegibilidad requirió disponibilidad en línea del texto completo y edición en inglés o español. Se incluyeron estudios que (i) implementaran tecnologías de Industria 4.0 en mantenimiento; (ii) propusieran modelos de gestión del mantenimiento basados en dichas tecnologías; (iii) presentaran modelos validados mediante simulaciones con datos reales; (iv) desarrollaran marcos conceptuales sin verificación empírica; y (v) emplearan metodologías cualitativas, cuantitativas o mixtas. Se excluyeron editoriales, cartas al editor, revisiones y metaanálisis.

Los artículos elegibles fueron sometidos a análisis de contenido por el investigador, utilizando una ficha de extracción para registrar: año de publicación, país de la revista, filiación institucional de los autores, metodología, objetivos, sujetos de estudio, tema y área de aplicación.

Definición y esquema de categorización de variables:

Con el fin de asegurar comparabilidad entre estudios heterogéneos, las variables se definieron, delimitaron y clasificaron mediante un marco de codificación y categorización de indicadores observables, estructurado en las siguientes dimensiones:

- a) Año de publicación (2014–2025): inclusión de trabajos con acceso electrónico íntegro al artículo.
- b) Área temática: mantenimiento articulado con tecnologías de Industria 4.0.
- c) Metodología: cualitativa, cuantitativa o mixta; se consignó la naturaleza predominante del enfoque.
- d) Sujetos de estudio: equipos y máquinas individuales, plantas industriales de diversos rubros, sistemas de producción y distribución de energía y combustibles, edificación inteligente, transporte de carga y minería.
- e) Filiación institucional de los autores: académica universitaria y/o sector industrial.
- f) Continente de origen de los artículos científicos: África, América del Norte, América del Sur, Asia, Europa y Oceanía.

Este procedimiento permitió alinear constructos conceptuales con evidencias observables y facilitar la síntesis descriptiva y comparativa.

La revisión se efectuó mediante lectura íntegra de cada artículo, con énfasis en materiales y métodos y en resultados. Los datos se sistematizaron en una planilla Excel para su registro, el cálculo de medidas de asociación y la elaboración de tablas de resumen (Abidi et al., 2022; Aminzadeh et al., 2025; Arena et al., 2022; Ayyamperumal et al., 2025; Bondin & Zammit, 2024; Borro et al., 2021; Burmeister et al., 2023; Canizo et al., 2017; Ceruti et al., 2019; Christou et al., 2020; Dinh et al., 2020; El Kihel et al., 2021; Elkhenin & Mrad, 2025; Giacotto et al., 2021; Giannoulidis et al., 2025; Godoy et al., 2024; Gomaa, 2025; Gutschi et al., 2019; Haripriya et al., 2025; Hassan et al., 2024; Janssens et al., 2023; Jena et al., 2024; Ji & Xu, 2025; Kanoun et al., 2024; Korchagin et al., 2022; Liu et al., 2022; Liu et al., 2025; Marti-Puig et al., 2024; Mohan et al., 2023; Mohapatra et al., 2023; Murtaza et al., 2024; Nagy et al., 2025; Nalawade et al., 2024; Nentwich & Reinhart, 2021; Nordal & El-Thalji, 2021; Nsor, 2024; Ocaña Pañora et al., 2025; Park et al., 2017; Prabhakaran et al., 2022; Rajaoarisoa et al., 2025; Sang et

al., 2021; Sekar et al., 2025; Seneviratne et al., 2018; Sipos et al., 2014; Sittón-Candanedo et al., 2018; Taş, 2024; Wang et al., 2019; Wang et al., 2024; Yang et al., 2017; Zhang et al., 2024).

3 Resultados

En este capítulo se dan a conocer los principales resultados de este estudio. La tabla 1, nos indica la procedencia por continente y año de publicación de los artículos revisados. Según se puede observar la mayor contribución la tiene Europa con un 42%, seguido de Asia con un 34% y en tercer lugar Norteamérica con un 14%. La contribución de África, Sudamérica y Oceanía son marginales, totalizando estas un 8%. En cuanto al año de publicación, podemos ver un aumento en la cantidad de publicaciones desde 2021 en adelante, alcanzando el máximo en 2024 y 2025, con 12 artículos en cada año, alcanzando una distribución combinada de un 48% del total, siendo Europa, Asia y Norteamérica nuevamente los máximos exponentes.

Tabla 1: Distribución de artículos según año de publicación y continente de procedencia. Fuente: elaboración propia.

CONTINENTE DE PROCEDENCIA DE LOS ARTICULOS															
AÑO PUBLICACION	AFRICA		ASIA		EUROPA		NORTEAMERICA		OCEANIA		SUDAMERICA		SUDAMERICA / EUROPA		
	n	%	n	%	n	%	n	%	n	%	n	%	n	%	
2014							1	14%							1
2017			2	12%	1	5%									3
2018					2	10%									2
2019			1	6%	2	10%									3
2020					2	10%									2
2021	1	50%			4	19%							1	100%	6
2022			3	18%	2	10%									5
2023			2	12%	2	10%									4
2024			5	29%	2	10%	4	57%			1	100%			12
2025	1	50%	4	24%	4	19%	2	29%	1	100%					12
total (n/%)	2	4%	17	34%	21	42%	7	14%	1	2%	1	2%	1	2%	50

Con respecto a palabras claves, podemos indicar que totalizan 260, y que fueron reunidas en 20 grupos, por área temática común. La distribución global por agrupación de palabras claves, la podemos apreciar en las figuras 1 y 2. Por razones de mejorar la exposición de los resultados, se crea un macrogrupo (figura 1) que corresponde a “tecnologías I4.0” concentrando el 19,2%, seguido de Mantenimiento predictivo (PdM) con un 12,3%, Industria 4.0 con un 11,2% y Gestión Mantenimiento con un 10,8%. El resto de las contribuciones se reparte entre Manufacturing, Monitoreo de condición, Métodos matemáticos, Big Data & Cloud, CMMS/ERP & EAM, entre otros. La figura 2 detalla los cuatro componentes originales respecto del total: Machine Learning 8,5%, IoT/IIoT & Edge 6,2%, Gemelos digitales 2,7% y AI 1,9%, confirmando la centralidad tecnológica del portafolio investigado.

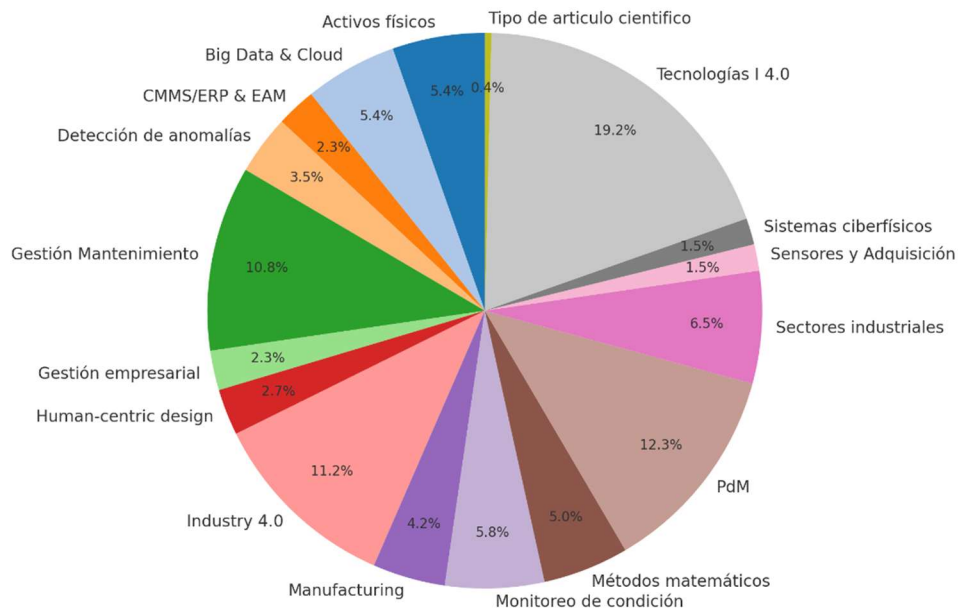


Figura 1: Distribución de conceptos claves de las publicaciones. Fuente: elaboración propia.




Figura 2: Disgregación del macro grupo “Tecnologías I4.0”. Fuente: elaboración propia.

La figura 3 que es un gráfico de barras apiladas por continente, muestra como era de esperar, una mayor producción en Europa y Asia, con Norteamérica en un nivel intermedio y volúmenes reducidos en Sudamérica, Oceanía y África. La categoría Sudamérica–Europa evidencia colaboraciones interregionales. La composición temática por continente replica el patrón global: presencia destacada de PdM, Industry 4.0, Gestión Mantenimiento y el bloque Tecnologías I4.0, mientras que los clústeres restantes exhiben contribuciones más acotadas.




Figura 3: Distribución de grupos de palabras clave por continente. Fuente: elaboración propia.

Los mapas de calor (figuras 4 y 5) complementan la lectura geográfica. Según la figura 4, a nivel continente vs. agrupación temática, las celdas de mayor intensidad se concentran en Europa y Asia, evidenciando una distribución temática amplia, que en el caso de Europa los máximos los encontramos con mantenimiento predictivo y gestión mantenimiento, a su vez predominan en Asia Gestión mantenimiento y machine learning. En Norteamérica destacan aportes homogéneos en la mayoría de las áreas temáticas y en África, Oceanía y Sudamérica aparecen nichos específicos y celdas en cero que sugieren brechas regionales.




Figura 4: Mapa de calor de continentes vs agrupación temática de palabras claves. Fuente: elaboración propia.

La figura 5, “país vs. agrupación temática” confirma la concentración en naciones con ecosistemas científicos consolidados, destacando India, China, Canadá y España, con preferencias en: gestión mantenimiento, machine learning, monitoreo de condición, mantenimiento predictivo, big Data & cloud, IoT/IIoT & Edge, human centric design, industria 4.0 y activos físicos.




Figura 5: Mapa de calor de países vs agrupación temática de palabras claves. Fuente: elaboración propia

3.1 Análisis de resultados

¿Cuál es el tema central de los trabajos?

Los trabajos convergen en un eje guiado por la evidencia operacional, en otras palabras, basada en datos, para Mantenimiento 4.0: uso de IoT/IIoT, adquisición multisensorial y analítica ML con enfoque PHM (pronóstico y gestión de salud de los activos) habilitan CBM en conjunto con PdM en

sectores diversos como el ferroviario, eólico, minería, petróleo y gas, manufactura discreta, *sistemas de calefacción ventilación y aire acondicionado* (HVAC) y *edificios energía cero* (NZEB). Se refuerza la integración edge-cloud, la interoperabilidad (bajo estándar de comunicación de automatización OPC UA) y el cierre del ciclo con CMMS, mientras los gemelos digitales emergen como columna vertebral para diagnóstico, pronóstico y planificación. En paralelo, la realidad aumentada y la manufactura aditiva apoyan actividades de *mantenimiento, reparación y revisión* (MRO) y capacitación. La divergencia aparece en el grado de madurez: algunos proponen marcos prescriptivos completos; otros se limitan a validaciones de subsistemas. Persisten vacíos en estandarización, trazabilidad y gobernanza de datos y modelos.

Destaca el valor académico de arquitecturas y métodos híbridos de redes neuronales: CNN-LSTM (*red neuronal convolucional – long short term memory*) para máquinas herramienta, LSTM (para RUL, *Inteligencia artificial explicable* (XAI) combinada con *autoencoders* y *DEVS* en eólica, y fusión de análisis térmicos y vibracional en equipos rotativos. Se aportan líneas poco exploradas, por ejemplo: PdM basado en *datos históricos de registro de eventos* (logs), aprendizaje no supervisado con KPIs específicos de *estrategias reactivas “funcionamiento hasta que falle”* (RTF: un-to-failure) y uso de *sistemas de apoyo a la decisión con lógica difusa* (fuzzy DSS) para motores diésel, así como marcos RCM 4.0/“smart RCM” y arquitecturas de gemelo digital de referencia para equipos rotativos y sistemas de tuberías. La contribución metodológica se amplía con optimización prescriptiva (programación entera mixta, Jaya/SLO) y evaluación económica robusta de PdM frente a correctivo, cerrando brechas entre promesas tecnológicas y desempeño empresarial medido.

Las implicaciones prácticas son consistentes: incrementos en disponibilidad y OEE, reducción de paradas no planificadas y de costos de ciclo de vida, mejoras de seguridad operacional y eficiencia energética como en los casos del tren de alta velocidad sur coreano y metros urbanos hasta prensas de conformado, HVAC y NZEB. La digitalización de flotas de camiones mineros y buses con telemetría, AR y plataformas cloud permite mantenimiento proactivo y documentación fiable. La integración de CMMS y gemelos digitales favorece la programación dinámica y la priorización por criticidad. No obstante, la escalabilidad a flotas masivas exige curación de datos, control de falsos positivos y mecanismos de actualización continua de modelos bajo deriva.

Se proyectan líneas de investigación claras: normalización semántica e interoperabilidad (AAS/OPC UA) con trazabilidad extremo a extremo; cuantificación de incertidumbre en pronóstico y reglas de decisión costo-riesgo; XAI aplicada a cumplimiento, confianza operativa y auditoría; fusión multimodal (vibración, infrarrojo: IR, acústica, logs) y aprendizaje continuo en el edge para latencias críticas; ciberseguridad de sistemas ciberfísicos y protección de datos industriales; diseño para el mantenimiento con gemelos digitales desde la concepción; y estudios longitudinales multicentro (seguimiento de activos a lo largo del tiempo en múltiples sitios independientes) con benchmarks abiertos que vinculen métricas técnicas (*vida útil remanente*: RUL, RAMS, OEE) con resultados económicos y ambientales en la transición hacia Industria 5.0.

¿Cuáles son los sujetos de estudio de las publicaciones?

Los sujetos de estudio identificados en los artículos se distribuyen desde componentes críticos como rodamientos, engranajes, husillos, transformadores y cajas de engranajes, hasta sistemas y flotas complejas en transporte ferroviario, aviación, minería y buses urbanos, además de plantas de proceso (fundición, cemento, compresión de gas) y entornos edificios HVAC/NZEB. Converge así un espectro que va del banco experimental y el gemelo digital controlado a escenarios operativos con telemetría real y registros de PLC a gran escala. Divergen niveles de granularidad, madurez tecnológica y disponibilidad de etiquetas, no obstante, persisten lagunas en activos lineales y en comparabilidad

entre dominios. La diversidad geográfica y sectorial refuerza la validez externa, pero evidencia heterogeneidad de datos y prácticas.

En términos metodológicos, destacan los siguientes aportes originales: uso exclusivo de logs de PLC para inferir fallas sin sensorización adicional, fusión térmica-vibracional y análisis de imágenes 3D de desgaste, guiado por OPC UA para interoperabilidad, y gemelos digitales con trazabilidad físico-estadística para propagación de grietas en cañerías. Plataformas como *PROPHESY-PdM* (Plataforma para el despliegue rápido de servicios de mantenimiento predictivo optimizados y autoconfigurables) integran modelos RUL y detección de eventos raros, mientras enfoques RCM 4.0 articulan AI, IIoT y analítica Big Data. Estudios a nivel empresa de adopción PdM con tecnologías de industria 4.0 amplían la mirada más allá del equipo, y casos MRO con AR exploran impactos organizacionales. Esta variedad aporta evidencia multiescalar y multipropósito, aunque con diseños y métricas aún poco estandarizados.

Las implicaciones sugieren avanzar hacia marcos comparables entre sectores, ontologías comunes para activos lineales y repositorios abiertos con series largas y clases desbalanceadas. Se proyecta consolidar gemelos híbridos físico-datos con incertidumbre explícita y evaluación económica integral, escalar del componente a la línea y la planta, e incorporar al mantenedor en el bucle mediante interfaces operativas validadas en campo. Áreas prioritarias incluyen generalización interdominio, protocolos de gobernanza de datos y medición de beneficios en disponibilidad, OPEX y huella energética en contextos reales (HVAC, NZEB, procesos continuos). La agenda futura debe combinar replicabilidad, métricas armonizadas y validación cruzada en flotas y geografías diversas.

¿Qué metodología o marco metodológico se aplicó en las investigaciones?

Predomina un eclecticismo metodológico articulado en tres corrientes convergentes: (i) analítica *data-driven* (basada en datos) con aprendizaje automático profundo y convencional, (ii) modelos físico-informados y gemelos digitales de distinta fidelidad, y (iii) marcos de excelencia operacional (RCM/TPM, RAMS, Lean Six Sigma, DMAIC). Se observan arquitecturas y modelos de datos maduros que abarcan desde la sonorización hasta la acción de mantenimiento, que integran IoT/IIoT, preprocesamiento riguroso, selección de variables y validación con métricas estandarizadas, además de despliegues edge-cloud que habilitan monitoreo en línea. La simulación (DES, Monte Carlo) y la optimización (GA, PSO, MIP) fortalecen la toma de decisiones, mientras la multimodalidad sensorica y la fusión de datos incrementan sensibilidad diagnóstica y pronóstica en escenarios industriales reales.

El valor académico se expresa en contribuciones metodológicas originales: integración XAI para interpretabilidad, esquemas *gray-box* y bayesianos que acoplan conocimiento físico con datos, aprendizaje multiinstancia para eventos raros y arquitecturas híbridas que combinan LSTM/CNN con reglas DEVS o DSS difusos. Destacan validaciones longitudinales y comparativas contra baselines, así como marcos de interoperabilidad (OPC UA, FIWARE) y auditorías 4.0 que aseguran trazabilidad entre requisitos RAMS y decisiones prescriptivas. La incorporación de AR en inspección y soporte técnico, junto con dashboards operativos, mejora la adopción organizacional y cierra el ciclo de mejora continua en contextos de alta automatización.

En términos de coherencia disciplinar, las metodologías alinean diagnóstico, pronóstico y prescripción: desde detección de anomalías y estimación de RUL hasta planificación multicomponente sujeta a costos y restricciones. Convergen los siguientes sectores industriales diversos: ferroviario, aeronáutico, minero, cementero y edificación NZEB, con KPIs técnicos de aprendizaje y de predicción como: *precisión, puntuación F1, área bajo la curva (AUC), error absoluto medio (MAE)*, y operacionales: OEE, MTBF y MTTR. Persisten brechas en el etiquetado de datos (costoso y

escaso), el desbalance de clases y la deriva de datos-modelos con el tiempo; además, se mantienen tensiones entre *precisión y explicabilidad* (mientras más exacto y potente es un modelo de aprendizaje es más difícil de comprender su lógica interna). También hay lagunas en causalidad (distinguir causa de correlación), en replicabilidad entre sitios/planta y en la evaluación de impactos energéticos y ambientales. Finalmente, urge estandarizar las *operaciones de aprendizaje automático* (MLOps) para asegurar robustez y gestión del ciclo de vida del modelo en operación.

Las proyecciones priorizan gemelos digitales híbridos como sustrato para mantenimiento prescriptivo, aprendizaje continuo y simulación de escenarios, junto con gobierno de datos, ciberseguridad y normalización interoperable. Se vislumbran líneas futuras en *Aprendizaje federado por transferencia*, robustez a cambios de régimen, fusión multimodal explicable, y marcos económicos que integren incertidumbre y huella ambiental en la optimización. De los artículos se vislumbra que las arquitecturas como: diseños HMI (interfaz hombre-maquina, por lo general paneles o pantallas) con AR, la validación multicriterio (técnico, económica, ambiental y organizacional) y los ensayos controlados en campo consolidarán la externalidad de resultados y su escalamiento industrial, acercando la disciplina a principios de resiliencia y sostenibilidad propios de Industria 5.0.

¿En qué contexto, sector o región se desarrollan estas investigaciones?

Los contextos analizados abarcan transporte (metro indio, alta velocidad coreana, aviación europea-australiana, buses urbanos), energía (eólica europea, redes eléctricas chinas, termoeléctricas y Petroleo-gas en Noruega, Quebec y Ecuador), manufactura avanzada (CNC, robótica automotriz en Europa y Turquía, fundición en India, cementera en Odisha-India), edificación e infraestructura (NZEB en China, HVAC en España, saneamiento urbano en India, tuberías críticas). Convergen en activos de alta criticidad, presión por disponibilidad y adopción de IoT-IA-gemelos digitales en entornos no estacionarios y regulados; divergen en madurez digital y restricciones locales. Persisten lagunas en comparativas interregionales, validaciones longitudinales y cobertura equitativa de Latinoamérica y África.

El valor académico reside en marcos replicables y validados industrialmente: arquitecturas ciberfísicas en talleres europeos, integración *BIM-IoT* (building information modeling) en NZEB, analítica en la nube para parques eólicos, PdM no invasivo en líneas CNC, soporte a decisión con AR en ductos, control de falsas alarmas a nivel de episodio y análisis económico regional (países V4: Chequia, Hungría, Polonia y Eslovaquia). Se proyectan implicaciones en escalabilidad multinodal, interoperabilidad, eficiencia energética y operación remota segura. Futuros trabajos deberían profundizar en robustez ante no estacionariedad, métricas de sostenibilidad integradas, costo-beneficio en pymes y países en desarrollo, ciberseguridad y gobernanza de datos, así como transferencia formativa para cerrar brechas de adopción.

3.2 Discusión de Resultados

¿Cuáles son los principales hallazgos o resultados técnicos presentados por los artículos analizados?

Los trabajos convergen en una sinergia madura entre IoT, analítica de datos, aprendizaje automático y gemelos digitales para diagnóstico, prognosis y decisiones prescriptivas en tiempo casi real. Se validan incrementos sustantivos de confiabilidad y disponibilidad en sectores ferroviario, eólico, minero, HVAC, CNC y cementero, con reducciones de inactividad no planificada y ahorros económicos cuantificados. La precisión técnica muestra techos altos en clasificaciones y estimaciones de RUL (algunos casos cercanos al 100%) y beneficios operacionales medidos en OEE, costes y seguridad. La estandarización arquitectónica (OPC UA, edge-cloud) y los marcos integrados (RCM

4.0, smart RCM) apuntalan la escalabilidad, la interoperabilidad y el cierre del ciclo desde la detección hasta la acción (Murtaza et al., 2024; Nsor, 2024; Ji & Xu, 2025; Jena et al., 2024)

El valor académico reside en contribuciones metodológicas que combinan modelos explicables, optimización y control: *AE-DEVS* aporta trazabilidad; *PMMI 4.0* con planificación multicomponente integra prognosis con calendarización; *SPMF* (Stochastic Process Mining Framework, software de minería de datos) materializa mantenimiento prescriptivo; *PROPHECY-PdM* y arquitecturas híbridas habilitan despliegue modular; los gemelos digitales incorporan actualización bayesiana y fusión multisensor. En el plano algorítmico, se evidencian rendimientos sobresalientes de ensambles (*XGBoost*: biblioteca de machine learning de código abierto), LSTM/CNN-LSTM y enfoques híbridos, junto con estrategias data-lite (log-based PdM, MIL: *aprendizaje multiinstancia*) y ELM (*Extreme Maching Learning*) de entrenamiento ultrarrápido, confirmando que la selección de variables, la multimodalidad y la gobernanza de datos son determinantes del desempeño (Rajaoarisoa et al., 2025; Christou et al., 2020; Sang et al., 2021; Giacotto et al., 2021).

Coexisten divergencias y límites indicadas a continuación: (i) precisiones moderadas en contextos HVAC contrastan con desempeños casi perfectos en rodamientos, (ii) los gemelos digitales son sensibles a cambios operacionales no fallidos, exigiendo gestión del contexto, (iii) la ergonomía de AR condiciona su adopción, y (iv) la efectividad del PdM varía por país y severidad de fallas. Persisten retos de transferibilidad entre familias de equipos, riesgo de sobreajuste temporal, sintonía de hiperparámetros y cuantificación de incertidumbre. La estandarización y la conformidad (p. ej., ISO/IEC 30141, ATEX) emergen como prerrequisitos para escalar soluciones seguras e interoperables en entornos industriales heterogéneos (Sittón-Candanedo et al., 2018; Hassan et al., 2024; Borro et al., 2021; Nagy et al., 2025).

Las proyecciones indican consolidación de ciclos cerrados diagnósticos-prescriptivos, integración de RUL “desde el diseño”, y optimización técnica-económica y de sostenibilidad en lo referente a mejoras energéticas y ambientales. Se vislumbran líneas de investigación en causalidad y explicabilidad operacional, robustez a la *deriva de datos*: drifts y dominios cambiantes, fusión multimodal con sensores económicos, arquitectura edge-cloud con garantías de ciberseguridad, y planificación óptima multicomponente bajo incertidumbre. La evidencia económica y los DSS cuantitativos refuerzan la adopción estratégica del PdM, mientras que la convergencia con principios de Industria 5.0 demanda enfoques *human-in-the-loop* (las personas participan activamente en entrenamiento de IA) y métricas integradas de desempeño, riesgo e impacto ambiental (Bondin & Zammit, 2024; Arena et al., 2022; Murtaza et al., Wang et al., 2024).

¿Qué mejoras operativas específicas o beneficios concretos se observaron tras la implementación de los modelos o tecnologías descritas?

Los estudios convergen en reducciones sustantivas de inactividad no planificada, ahorros de costos y mayor disponibilidad, con mejoras emblemáticas como OEE +46,9%, disponibilidad del 87,2 al 98,1% y reducción de MTTR en un 16,9%. La anticipación de fallas mediante PdM, gemelos digitales y analítica en tiempo real optimiza la programación y evita intervenciones prematuras, mientras arquitecturas edge-cloud y aprendizaje federado aceleran la respuesta y preservan datos. Los sectores industriales indicados: manufactura, energía, transporte, aeroespacial y facilities, reportan beneficios adicionales en materia de eficiencia energética, seguridad operativa y calidad del producto. Persisten heterogeneidades sectoriales y brechas de evidencia en trabajos conceptuales o simulados, pero la direccionalidad es clara hacia operaciones más robustas, trazables y sostenibles (Mohan et al., 2023; Jena et al., 2024; Nsor, 2024; Christou et al., 2020).

El valor académico se manifiesta en innovaciones metodológicas, siendo el caso: (i) curvas de confiabilidad condicional para políticas adaptativas, (ii) integración multimodal con: vibración, térmica, energía, para diagnósticos robustos, (iii) mitigación de fatiga de alarmas vía optimización de umbrales; y (iv) cuantificación de incertidumbre en interfaces AR/gemelo digital. Se incorporan estándares y plataformas (SCADA, OPC UA, EAM: *software de gestión de activos empresariales*, ERP), y estimadores económicos (Hodges–Lehmann) que vinculan desempeño técnico con impacto financiero, incluidos ahorros anuales del 25% y reducciones de costos directos de producción a escala país. Casos con drones y robots disminuyen exposición a riesgo y mejoran cobertura de inspección, mientras que decisiones dinámicas coordinan mantenimientos grupales, racionalizando inventarios y tiempos de setup (Godoy et al., 2024; Janssens et al., 2023; Giannoulidis et al., 2025; Wang et al., 2024).

Las proyecciones sugieren consolidar métricas comparables (OEE, MTBF/MTTR, RUL) y diseños cuasi-experimentales que identifiquen causalidad y externalidad entre plantas. Son prioritarias la ciberseguridad de IoT, la gobernanza de datos y la interoperabilidad semántica para escalar entre sitios. Se demandan evaluaciones de ciclo de vida que integren energía y emisiones y modelos de costo-riesgo que optimicen repuestos y vida útil. La agenda futura incluye cerrar la brecha simulación real, adaptar modelos a variabilidad operativa, y profundizar factores humanos en la adopción, garantizando explicabilidad y confianza del operador sin sacrificar rendimiento predictivo ni velocidad de decisión (Hassan et al., 2024; Ceruti et al., 2019; Ji & Xu, 2025; Bondin & Zammit, 2024).

¿Cuáles son las principales fortalezas y debilidades que se identifican en las propuestas implementadas en los distintos estudios?

Las propuestas convergen en arquitecturas integradas que combinan IoT/IIoT, analítica avanzada, gemelos digitales, edge/federated computing y plataformas interoperables industriales, permitiendo diagnóstico y prognosis en tiempo real, alta precisión predictiva y escalabilidad multisitio. Se observan aportes en explicabilidad, reglas auditables y sistemas end-to-end (de inicio a fin) que conectan sensado, inferencia y decisión, con reportes de retornos económicos y reducciones de paradas. Divergen en el énfasis entre modelos “caja negra” y enfoques interpretables, así como en el grado de automatización y autonomía. Persisten vacíos en evaluaciones longitudinales y comparativas entre sectores intensamente regulados (Nsor, 2024; Nagy et al., 2025; Wang et al., 2024)

Las debilidades a las que apuntan las publicaciones son estructurales: (i) dependencia crítica de la calidad, cobertura y etiquetado de datos, (ii) desbalance de clases y ruido, (iii) altos costos iniciales y requerimientos de infraestructura, y (iv) dificultades de integración con sistemas legados y brechas de ciberseguridad. Limitan la generalización los estudios de caso único, validaciones en banco de pruebas y uso extensivo de simulaciones. Surgen fricciones organizacionales como: capacidades digitales, resistencia cultural y sindical, y restricciones normativas en sectores como aeronáutica y petróleo. También se evidencian sensibilidades a la parametrización, deriva de datos y esfuerzos intensivos de calibración y mantenimiento de modelos (Sekar et al., 2025; Sipos et al., 2014; El Kihel et al., 2021; Nagy et al., 2025).

En términos de valor académico, destacan contribuciones metodológicas que integran aprendizaje profundo con optimización, actualización bayesiana en gemelos digitales, aprendizaje por refuerzo para políticas adaptativas y marcos híbridos físico–datos; además, evidencia estadística robusta respalda inferencias causales y decisiones gerenciales. La explicabilidad emerge como vía para confianza operativa, auditoría y transferencia de conocimiento, mientras que modelos parsimoniosos ofrecen interpretabilidad y bajo costo computacional frente a ensamblajes complejos. Persisten divergencias sobre el “punto dulce” entre desempeño y transparencia, y sobre cuándo la simplicidad

supera a arquitecturas profundas en entornos con datos limitados o volátiles (Wang et al., 2024; Nagy et al., 2025; Arena et al., 2022; Ayyamperumal et al., 2025).

Las proyecciones priorizan estandarización semántica, interoperabilidad y estudios multisectoriales a escala, junto con evaluaciones tecno-económicas de largo plazo y métricas de impacto operacional. Se perfilan líneas futuras en XAI en tiempo real, mitigación de data drift y “*olvido catastrófico*” de una red neuronal, seguridad y privacidad por diseño, y ergonomía de interfaces AR. Urge fortalecer datos de campo, cerrar la brecha PyME mediante soluciones modulares y low-cost, y desarrollar marcos regulatorios que acompañen la manufactura avanzada. La transferencia efectiva entre equipos internos y contratistas y la maduración de pruebas en condiciones reales serán claves para una adopción sostenible (Christou et al., 2020; Nordal & El- Thalji, 2021; Prabhakaran et al., 2022; Nagy et al., 2025).

¿Qué métricas o indicadores se utilizaron para validar la efectividad técnica o económica de las propuestas implementadas?

Las métricas se organizan en cuatro familias: técnicas de predicción y diagnóstico (precisión, recall, puntuación F1, AUC, PR-AUC: *área bajo la curva de precisión-recuperación*, MAE, MAPE: *error porcentual absoluto medio*, R²: *coeficiente de determinación*), de confiabilidad RAMS y vida útil (MTBF, MTTR, RUL, disponibilidad, mantenibilidad), de desempeño operativo (reducción de downtime, OEE, tiempos de respuesta, latencias) y de impacto económico-ambiental (ROI: *retorno de inversión*, costos unitarios y evitados, inventarios, eficiencia energética y CO₂). Esta taxonomía permite comparar enfoques que van desde clasificación y pronóstico hasta evaluación estructural con uno de análisis de elementos finitos y rendimiento de redes industriales, mostrando una convergencia hacia métricas híbridas que conectan exactitud predictiva con consecuencias operativas y financieras (Murtaza et al., 2024; Nsor, 2024; Jena et al., 2024; Ceruti et al., 2019).

El valor académico reside en contribuciones metodológicas que afinan la evaluación, tales es el caso de: métricas sensibles al “lead time” (puntuación F2, KPIs de evaluación de detección de anomalías) para eventos incipientes, PM-AUC específica para PdM, integración de tableros con DAX/Power BI para cálculo en tiempo real y marcos econométricos no paramétricos y árbol *CART* (algoritmo basado en árboles de decisión) que identifico umbrales de ventas netas. Los estudios comparan algoritmos (por ejemplo: XGBoost, LSTM, RL: *reinforcement learning*) y cuantifican beneficios combinando reducción de paradas, mejora de OEE y ahorros, ampliando la pertinencia disciplinar hacia decisiones de gestión sustentadas en evidencia (Giannoulidis et al., 2025; Sipos et al., 2014; Elkhenin & Mrad, 2025; Nagy et al., 2025).

Se evidencian divergencias en la cobertura de dimensiones económicas y ambientales, con varios trabajos que reportan métricas técnicas sin costos ni incertidumbre asociada. La heterogeneidad de umbrales, ventanas y criterios de éxito dificulta la reproducibilidad, y las precisiones cercanas al 100% sugieren riesgo de sobreajuste si no median validaciones externas y análisis de sensibilidad. También sale a relucir la falta de estandarización para cuantificar costos por falsas alarmas u omisiones, evaluar utilidad esperada y reportar incertidumbre en RUL, así como protocolos de benchmarking inter-plantas con datos reales (Janssens et al., 2023; Mohan et al., 2023; Nentwich & Reinhart, 2021; Bondin & Zammit, 2024).

Se proyecta consolidar un marco multicriterio que jerarquice indicadores según objetivos de seguridad, confiabilidad, costo o sostenibilidad e incorpore curvas costo-consecuencia, utilidad esperada y métricas de anticipación temporal. Es prioritario normalizar un “núcleo mínimo” de reportes (por ejemplo: PR-AUC o AUC, F1/F2, error de RUL, downtime evitado, OEE, ROI, Costos unitarios esperados y huella de carbono) enlazado a sistemas informáticos de gestión de

mantenimiento y de activos (CMMS, EAM) para auditoría. La creación de benchmarks abiertos por sector y la trazabilidad de decisiones en tableros reproducibles fortalecerán la transferencia industrial y la generalización de resultados (Arena et al., 2022; Wang et al., 2024; Giacotto et al., 2021; ; Nsor, 2024).

¿Cuáles son las implicaciones y proyecciones estratégicas para la industria derivadas de los resultados, y qué desafíos pendientes o áreas de mejora condicionan su implementación y orientan la agenda de futuras investigaciones?

La evidencia converge en una proyección de mantenimiento intensivo en datos, autónomo y escalable, con adopciones transversales en transporte, energía, construcción y servicios urbanos. Se anticipan reducciones sostenidas de fallas e inactividad, mejoras en disponibilidad y eficiencia energética, y una competitividad reforzada por gemelos digitales, IoT, analítica avanzada y decisiones prescriptivas en tiempo real. La digitalización de activos y la integración nube–borde habilitan trazabilidad, resiliencia y alineamiento con objetivos ESG (medio ambiente, sociedad y gobierno corporativo), mientras ciudades y plantas inteligentes consolidan gobernanza basada en datos y operaciones seguras. Estas transformaciones desplazan el rol humano hacia supervisión experta y planificación estratégica (Nsor, 2024; Nagy et al., 2025; Wang et al., 2019; Haripriya et al., 2025)

En términos de valor disciplinar, destacan contribuciones metodológicas orientadas a plataformas modulares y estandarizables de PdM, marcos híbridos PdM/CBM con simulación y Big Data, y portafolios CBM optimizados por criticidad y RUL. La escalabilidad y centralización de modelos, junto con interfaces visuales para no expertos, favorecen la transferencia intersectorial y el cierre del ciclo señal–orden de trabajo. La estandarización y la convergencia IA–IoT–analítica soportan decisiones en tiempo casi real y expansión a sistemas distribuidos. Estas propuestas fortalecen la reproducibilidad y el aprendizaje organizacional a nivel planta y multisitio (Christou et al., 2020; Wang et al., 2024; Murtaza et al., 2024; Nordal & El- Thalji, 2021).

No obstante, su implementación enfrenta brechas críticas: calidad, volumen y diversidad de datos en condiciones reales; interoperabilidad con ERP/CMMS y sistemas legados; ciberseguridad; y validación externa en contextos ruidosos y no estacionarios. Se requieren modelos robustos contra deriva de datos y ruido, mecanismos de autoajuste y distinción entre desgaste y factores exógenos. Persiste, además, la dimensión humana: capacitación en SCADA/analítica y mejoras de usabilidad en ergonomía de AR para aceptación en taller. Estas restricciones condicionan el escalamiento y la generalización a sectores y geografías con capacidades digitales heterogéneas (Seneviratne et al., 2018; Elkhenin & Mrad, 2025; Nentwich & Reinhart, 2021; Borro et al., 2021).

La agenda futura se orienta en los siguientes aspectos: XAI e integración con DSS para decisiones trazables, aprendizaje federado y fusión PB+DL (algoritmos *profile-based + deep learning*) para operar con datos sensibles y dispersos, detección automática de cambios de contexto y reajuste dinámico de umbrales y sistemas end to end acoplados a órdenes de trabajo. Se prioriza ampliar las bases de datos, manejar desbalance y validar multisitio, junto con integrar ERP/CMS y fortalecer ciberseguridad. El Edge computing y tecnologías de registro distribuido emergen para mejorar latencia y confiabilidad, mientras se exploran marcos de automatización y RL en entornos complejos. Todo ello busca consolidar PdM/CBM prescriptivo, escalable y económicamente sostenible. (Ayyamperumal et al., 2025; Giannoulidis et al., 2025; Canizo et al., 2017; Haripriya et al., 2025).

4 Conclusiones

Este trabajo establece que implementación de modelos de gestión del mantenimiento habilitados por tecnologías de Industria 4.0 reconfigura la función de mantenimiento y la alinea con la estrategia operacional. En consecuencia, la adopción de mantenimiento predictivo y de mantenimiento basado en condición reduce fallas y costos, mejora la disponibilidad y la eficacia global de los equipos, y fortalece decisiones sustentadas en datos. A su vez, la integración de sensores inteligentes, IoT e IIoT, analítica avanzada y gemelos digitales permite anticipar degradaciones, planificar intervenciones con mayor precisión y optimizar el uso de repuestos y recursos. Todo ello se observa de manera consistente en los sectores ferroviario, manufacturero, minero, automotriz y de edificación industrial, donde la coordinación entre operación y mantenimiento adquiere carácter sistémico. Además, los desafíos para una aplicación robusta en contextos industriales diversos se concentran en la interoperabilidad entre sistemas legados y plataformas modernas, en la calidad y la gobernanza de los datos, y en la ciberseguridad y el cumplimiento normativo. Igualmente, se evidencian brechas de capacidades para operar modelos analíticos en producción de manera sostenida. En esta línea, se requieren prácticas y herramientas que permitan desplegar, supervisar y mantener modelos de aprendizaje automático en ambientes reales durante todo su ciclo de vida, con monitoreo, versionado y trazabilidad técnica y económica. Asimismo, persisten tensiones entre precisión y explicabilidad, costos elevados de etiquetado, desbalance de clases y deriva de datos, junto con la ausencia de protocolos y métricas estandarizadas que faciliten el escalamiento multi sitio y la evaluación comparativa.

Para abordar estas brechas se determinaron tendencias de la implementación y se evaluaron sus efectos. En efecto la evidencia muestra que: los marcos de mantenimiento RCM adaptados a la lógica de Industria 4.0, evolucionan desde la condición hacia la prescripción de acciones priorizadas por criticidad y riesgo. Al mismo tiempo, los modelos híbridos que combinan aprendizaje automático y aprendizaje profundo mejoran la estimación de la vida útil remanente y la detección temprana de fallas incipientes. De igual modo, la sensorica multimodal conectada a sistemas SCADA y a controladores lógicos programables mediante el estándar de interoperabilidad OPC UA, junto con arquitecturas de procesamiento en el borde y en la nube, incrementa cobertura, oportunidad de respuesta y trazabilidad de eventos. Además, la integración con sistemas de gestión del mantenimiento y con sistemas de planificación de recursos empresariales posibilita priorizar órdenes, asignar recursos y medir impacto en desempeño, seguridad y energía.

En términos de desempeño, los estudios cuantifican resultados mediante indicadores de confiabilidad y mantenibilidad como MTBF, MTTR, vida útil remanente, disponibilidad y mantenibilidad, además de desempeño operativo como OEE y reducción de downtime, complementados con métricas de calidad predictiva y, en menor medida, variables económico-ambientales como ROI, costos evitados, eficiencia energética y CO₂. En casos emblemáticos se reportan incrementos de OEE de hasta 46,9 por ciento, alzas de disponibilidad desde 87,2 hasta 98,1 por ciento y reducciones de MTTR del orden de 16,9 por ciento, junto con ahorros anuales cercanos al 25 por ciento cuando la analítica se vincula con decisiones operacionales y financieras. No obstante, la heterogeneidad de umbrales y ventanas de evaluación limita la reproducibilidad y la comparación interplanta, y las precisiones cercanas al 100 por ciento sugieren riesgo de sobreajuste si no existen validaciones externas. Por ello, la evidencia converge hacia un núcleo mínimo de reportes que integre métricas de pronóstico, RAMS, downtime evitado, OEE y evaluación económica y ambiental para sostener decisiones auditables y trazables.

Respecto de estrategias y tecnologías por continentes, Europa prioriza arquitecturas de referencia de Industria 4.0 que articulan desde los activos y comunicación hasta las capas de negocio, junto con gemelos digitales y analítica integrada, lo que impulsa estandarización, calidad y cumplimiento, aunque exige mayor ciberseguridad y resguardo de datos. En Asia, la adopción masiva de Internet IoT, aprendizaje profundo y edge computing eleva productividad y flexibilidad, mientras persisten retos de heterogeneidad tecnológica y gobernanza de datos. En Norteamérica, nubes híbridas y analítica avanzada integradas a sistemas de mantenimiento y empresariales mejoran la planificación y reducen paradas, aunque enfrentan costos de cambio y sistemas legados. En América Latina, sobre todo en minería y manufactura, CBM con analítica eleva disponibilidad y seguridad, condicionado por conectividad, inversión y capacidades.

Dicho lo anterior, este trabajo aporta a la comprensión variables tecnológicas y organizacionales que condicionan la adopción y el escalamiento del mantenimiento digital. En el plano tecnológico, resultan críticos la calidad, la cobertura, la trazabilidad y la interoperabilidad de los datos de condición y operación, junto con la capacidad de desplegar y sostener modelos en producción mediante validación continua, versionado, monitoreo y control de deriva. En el plano organizacional, destacan las capacidades digitales del personal, la gestión del cambio frente a resistencias culturales y las restricciones normativas en sectores regulados, además de la necesidad de confianza operativa basada en explicabilidad y reglas auditables. En conjunto, estas variables explican por qué algunos estudios logran implementaciones robustas con telemetría real y resultados comparables, mientras otros permanecen en simulación o banco de pruebas, limitando la generalización y la replicabilidad multisitio.

4.1 Trabajos futuros

Para abordar las brechas detectadas en este proyecto se proponen las siguientes acciones prioritarias:

- Evaluar el impacto técnico-económico de tecnologías Industria 4.0 en mantenimiento.
- Diseñar arquitectura interoperable de extremo a extremo con sensórica calibrada, procesamiento en el borde y en la nube y protocolos abiertos.
- Fortalecer gobierno de datos y ciberseguridad industrial con políticas de calidad, linaje, acceso y protección a lo largo de toda la cadena.
- Profesionalizar operaciones de modelos en producción con despliegue, monitoreo, versionado y explicabilidad durante todo el ciclo de vida.
- Integrar CMMS y ERP con flujos bidireccionales y cuadros de mando para medir impacto en OEE, costos, seguridad y energía y priorizar por criticidad.

5 Referencias

- Abidi, M. H., Mohammed, M. K., & Alkhalefah, H. (2022). Predictive maintenance planning for Industry 4.0 using machine learning for sustainable manufacturing. *Sustainability*, 14(6), 3387. <https://doi.org/10.3390/su14063387>
- Alarcón M., A. M., & Astudillo D., P. (2007). La investigación en enfermería en revistas latinoamericanas. *Ciencia y Enfermería*, 13(2), 25–31. <https://doi.org/10.4067/S0717-95532007000200004>
- Aminzadeh, A., Sattarpanah Karganroudi, S., Majidi, S., Dabompre, C., Azaiez, K., Mitride, C., & Sénéchal, E. (2025). A machine learning implementation to predictive maintenance and monitoring of industrial compressors. *Sensors*, 25(4), 1006. <https://doi.org/10.3390/s25041006>
- Arena, S., Florian, E., Zennaro, I., Orrù, P. F., & Sgarbossa, F. (2022). A novel decision support system for managing predictive maintenance strategies based on machine learning approaches. *Safety Science*, 146, 105529. <https://doi.org/10.1016/j.ssci.2021.105529>
- Ayyamperumal, V., Prabu, S., Senthilraja, R., Ali, A. M., Jayapoorani, S., & Arun, M. (2025). AI-driven predictive maintenance for smart manufacturing systems using digital twin technology. *International Journal of Computational and Experimental Science and Engineering*, 11(1), 1350–1355. <https://doi.org/10.22399/ijcesen.1099>
- Bokrantz, J., Skoogh, A., Berlin, C., Wuest, T., & Stahre, J. (2020). Smart Maintenance: An empirically grounded conceptualization. *International Journal of Production Economics*, 223, 107534. <https://doi.org/10.1016/j.ijpe.2019.107534>
- Bondin, A., & Zammit, J. P. (2024). Leveraging Industry 4.0 techniques for predictive equipment maintenance: From concept to commissioning. *MATEC Web of Conferences*, 401, 13001. <https://doi.org/10.1051/mateconf/202440113001>
- Borro, D., Suescun, Á., Brazález, A., González, J. M., Ortega, E., & González, E. (2021). WARM: Wearable AR and tablet-based assistant systems for bus maintenance. *Applied Sciences*, 11(4), 1443. <https://doi.org/10.3390/app11041443>
- Burmeister, N., Frederiksen, R. D., Høg, E., & Nielsen, P. (2023). Exploration of production data for predictive maintenance of industrial equipment: A case study. *IEEE Access*, 11, 102025–102037. <https://doi.org/10.1109/ACCESS.2023.3315842>
- Canizo, M., Onieva, E., Conde, A., Charramendieta, S., & Trujillo, S. (2017). Real-time predictive maintenance for wind turbines using big data frameworks. In *Proceedings of the 2017 IEEE International Conference on Prognostics and Health Management (ICPHM)* (pp. 1–8). <https://doi.org/10.48550/arXiv.1709.07250>
- Carvalho, T. P., Soares, F. A. A. M. N., Vita, R., Francisco, R. P., Basto, J. P., & Alcalá, S. G. S. (2019). A systematic literature review of machine learning methods applied to predictive maintenance. *Computers & Industrial Engineering*, 137, 106024. <https://doi.org/10.1016/j.cie.2019.106024>
- Ceruti, A., Marzocca, P., Liverani, A., & Bil, C. (2019). Maintenance in aeronautics in an Industry 4.0 context: The role of augmented reality and additive manufacturing. *Journal of Computational Design and Engineering*, 6(4), 516–526. <https://doi.org/10.1016/j.jcde.2019.02.001>

- Christou, I. T., Kefalakis, N., Zalonis, A., Soldatos, J., & Bröchler, R. (2020). End-to-end industrial IoT platform for actionable predictive maintenance. *IFAC-PapersOnLine*, 53(3), 173–178. <https://doi.org/10.1016/j.ifacol.2020.11.028>
- Dinh, D.-H., Do, P., & Iung, B. (2020). Maintenance optimisation for multi-component system with structural dependence: Application to machine tool sub-system. *CIRP Annals – Manufacturing Technology*, 69(1), 429–432. <https://doi.org/10.1016/j.cirp.2020.04.004>
- El Kihel, A., Gziri, H., & Bakdid, A. (2021). Method of implementing Maintenance 4.0 in industry: A case study of an industrial system. *International Journal on Technical and Physical Problems of Engineering*, 13(4), 78–84. <https://doi.org/10.5281/zenodo.7646261>
- Elkhenin, N., & Mrad, H. (2025). Maintenance 4.0 in mining trucks: Data digitalization and advanced protocols. *Procedia Computer Science*, 253, 2147–2155. <https://doi.org/10.1016/j.procs.2025.01.275>
- Giacotto, A., Costa Marques, H., Pereira Barreto, E. A., & Martinetti, A. (2021). The need for Ecosystem 4.0 to support Maintenance 4.0: An aviation assembly line case. *Applied Sciences*, 11(8), 3333. <https://doi.org/10.3390/app11083333>
- Giannoulidis, A., Gounaris, A., Naskos, A., Nikolaidis, N., & Caljouw, D. (2025). Engineering and evaluating an unsupervised predictive maintenance solution: A cold-forming press case study. *Journal of Intelligent Manufacturing*, 36, 2121–2139. <https://doi.org/10.1007/s10845-024-02352-z>
- Godoy, D. R., Mavrakis, C., Mena, R., Kristjanpoller, F., & Viveros, P. (2024). An advanced framework for predictive maintenance decisions: Integrating the proportional hazards model and machine learning techniques under CBM multi-covariate scenarios. *Applied Sciences*, 14(13), 5514. <https://doi.org/10.3390/app14135514>
- Gomaa, A. H. (2025). RCM 4.0: A novel digital framework for reliability-centered maintenance in smart industrial systems. *International Journal of Emerging Science and Engineering*, 13(5), 32–41. <https://doi.org/10.35940/ijese.E2595.13050425>
- Gutsch, C., Furian, N., Suschnigg, J., Neubacher, D., & Voessner, S. (2019). Log-based predictive maintenance in discrete parts manufacturing. *Procedia CIRP*, 79, 528–533. <https://doi.org/10.1016/j.procir.2019.02.098>
- Haripriya, K., Preethi, C., Hamed, S., Pavalarajan, S., Sharon, S. A., & Suryakumar, S. (2025). Smart sanitation management: Integrating IoT, AI-driven analytics, and automated sensing for efficient public toilet maintenance. In *Proceedings of the International Conference on Machine Learning and Autonomous Systems (ICMLAS-2025)*. IEEE. <https://doi.org/10.1109/ICMLAS64557.2025.10967950>
- Hassan, M., Svadling, M., & Björnell, N. (2024). Experience from implementing digital twins for maintenance in industrial processes. *Journal of Intelligent Manufacturing*, 35, 875–884. <https://doi.org/10.1007/s10845-023-02078-4>
- Janssens, O., Loccufier, M., & Van Hoecke, S. (2023). Thermal imaging and vibration-based multi-sensor fault detection for rotating machinery. *IEEE Transactions on Industrial Informatics*, 19(1), 1–12. <https://doi.org/10.1109/TII.2023.3241236>
- Jena, M. C., Mishra, S. K., & Moharana, H. S. (2024). Integration of Industry 4.0 with reliability-centered maintenance to enhance sustainable manufacturing. *Environmental Progress & Sustainable Energy*, 43(2), e14321. <https://doi.org/10.1002/ep.14321>

- Ji, T., & Xu, X. (2025). Exploring the integration of cloud manufacturing and cyber-physical systems in the era of Industry 4.0: An OPC UA approach. *Robotics and Computer-Integrated Manufacturing*, 93, 102927. <https://doi.org/10.1016/j.rcim.2024.102927>
- Kanoun, Y., Mohammadi Aghbash, A., Belem, T., Zouari, B., & Mrad, H. (2024). Failure prediction in the refinery piping system using machine learning algorithms: Classification and comparison. *Procedia Computer Science*, 232, 1663–1672. <https://doi.org/10.1016/j.procs.2024.01.164>
- Korchagin, A., Deniskin, Y., Pocebneva, I., & Vasilyeva, O. (2022). Lean Maintenance 4.0: Implementation for aviation industry. *Transportation Research Procedia*, 63, 1521–1533. <https://doi.org/10.1016/j.trpro.2022.06.164>
- Liu, C., Zhu, H., Tang, D., Nie, Q., Zhou, T., Wang, L., & Song, Y. (2022). Probing an intelligent predictive maintenance approach with deep learning and augmented reality for machine tools in IoT-enabled manufacturing. *Robotics and Computer-Integrated Manufacturing*, 77, 102357. <https://doi.org/10.1016/j.rcim.2022.102357>
- Liu, Z., Li, M., & Ji, W. (2025). Development and application of a digital twin model for net zero energy building operation and maintenance utilizing BIM–IoT integration. *Energy and Buildings*, 328, 115170. <https://doi.org/10.1016/j.enbuild.2024.115170>
- Mantravadi, S., & Møller, C. (2019). An overview of next-generation manufacturing execution systems: How important is MES for Industry 4.0? *Procedia Manufacturing*, 30, 588–595. <https://doi.org/10.1016/j.promfg.2019.02.083>
- Marti-Puig, P., Amar Touhami, I., Colomer Perarnau, R., & Serra-Serra, M. (2024). Industrial AI in condition-based maintenance: A case study in wooden piece manufacturing. *Computers & Industrial Engineering*, 188, 109907. <https://doi.org/10.1016/j.cie.2024.109907>
- Mohan, R., Roselyn, J. P., & Uthra, R. A. (2023). LSTM-based artificial intelligence predictive maintenance technique for availability rate and OEE improvement in a TPM implementing plant through Industry 4.0 transformation. *Journal of Quality in Maintenance Engineering*. <https://doi.org/10.1108/JQME-07-2022-0041>
- Mohapatra, A. G., Mohanty, A., Pradhan, N. R., Mohanty, S. N., Gupta, D., Alharbi, M., Alkhayyat, A., & Khanna, A. (2023). An Industry 4.0 implementation of a condition monitoring system and IoT-enabled predictive maintenance scheme for diesel generators. *Alexandria Engineering Journal*, 76, 525–541. <https://doi.org/10.1016/j.aej.2023.06.026>
- Moleda, M., Malysiak-Mrozek, B., Ding, W., Sunderam, V., & Mrozek, D. (2023). **From corrective to predictive maintenance—A review of maintenance approaches for the power industry.** *Sensors*, 23(13), 5970. <https://doi.org/10.3390/s23135970>
- Murtaza, A. A., Saher, A., Zafar, M. H., Moosavi, S. K. R., Aftab, M. F., & Sanfilippo, F. (2024). Paradigm shift for predictive maintenance and condition monitoring from Industry 4.0 to Industry 5.0: A systematic review, challenges and case study. *Results in Engineering*, 24, 102935. <https://doi.org/10.1016/j.rineng.2024.102935>
- Nagy, M., Figura, M., Valaskova, K., & Lăzăroi, G. (2025). Predictive maintenance algorithms, artificial intelligence digital twin technologies, and Internet of Robotic Things in big data–driven Industry 4.0 manufacturing systems. *Mathematics*, 13, 981. <https://doi.org/10.3390/math13060981>

- Nalawade, N., Jakkan, S. D., Mangnale, S., & Patil, P. (2024). Predictive maintenance for industrial equipment using IIoT, AI and ML. *International Journal of Advance Research, Ideas and Innovations in Technology*, 10(6), 233–237. <https://www.ijariit.com/manuscripts/v10i6/V10I6-1334.pdf>
- Nentwich, C., & Reinhart, G. (2021). A combined anomaly and trend detection system for industrial robot gear condition monitoring. *Applied Sciences*, 11(21), 10403. <https://doi.org/10.3390/app112110403>
- Nordal, H., & El-Thalji, I. (2021). Modeling a predictive maintenance management architecture to meet Industry 4.0 requirements: A case study. *Systems Engineering*, 24(1), 34–50. <https://doi.org/10.1002/sys.21565>
- Nsor, M. (2024). Predictive maintenance using machine learning for engineering systems through real-time sensor data and anomaly detection models. *International Journal of Research Publication and Reviews*, 5(10), 5167–5183. <https://doi.org/10.55248/gengpi.6.0725.2541>
- Ocaña Pañora, L. S., Chiza Llambo, J. C., Tibanquiza Chuncho, S. E., & Moreno Garzón, G. P. (2025). Propuesta de transformación hacia la Industria 4.0 del monitoreo, inspección y mantenimiento de tanques reservorios de crudo en Ecuador. *AlfaPublicaciones*, 7(1.1), 49–73. <https://doi.org/10.33262/ap.v7i1.1.585>
- Park, S. C., Kim, Y. J., & Won, J. U. (2017). Application of IoT for the maintaining rolling stocks. *Quality Innovation Prosperity*, 21(2), 71–83. <https://doi.org/10.12776/qip.v21i2.887>
- Pech, M., Vrchota, J., & Bednář, J. (2021). Predictive maintenance and intelligent sensors in smart factory: Review. *Sensors*, 21(4), 1470. <https://doi.org/10.3390/s21041470>
- Prabhakaran, P., Anandakumar, S., Priyanka, B. E., & Velusamy, P. (2022). Model development synchronized with data mining for rolling stock maintenance strategy. *Advances in Mechanical Engineering*, 14(8), 1–17. <https://doi.org/10.1177/16878132221117124>
- Rajaoarisoa, L., Randrianandraina, R., Nalepa, G. J., & Gama, J. (2025). Decision-making systems improvement based on explainable artificial intelligence approaches for predictive maintenance. *Engineering Applications of Artificial Intelligence*, 139, 109601. <https://doi.org/10.1016/j.engappai.2024.109601>
- Sahli, A., Evans, R., & Manohar, A. (2021). Predictive maintenance in Industry 4.0: Current themes. *Procedia CIRP*, 104, 1948–1953. <https://doi.org/10.1016/j.procir.2021.11.329>
- Sang, G. M., Xu, L., & de Vrieze, P. (2021). A predictive maintenance model for flexible manufacturing in the context of Industry 4.0. *Frontiers in Big Data*, 4, 663466. <https://doi.org/10.3389/fdata.2021.663466>
- Sekar, K., Subbiah Nattar, M., Muthukamatchi, P., Ranganathan, N., Srithar, S., & Gurunathan, N. (2025). Integrating machine learning and IoT for real-time predictive maintenance in industrial ecosystems: A case study analysis. *International Journal of Research in Industrial Engineering*, 14(2), 385–409. <https://doi.org/10.22105/riiej.2025.502596.1531>
- Seneviratne, D., Ciani, L., Catelani, M., & Galar, D. (2018). Smart maintenance and inspection of linear assets: An Industry 4.0 approach. *Acta IMEKO*, 7(1), 50–56. https://doi.org/10.21014/acta_imeko.v7i1.535
- Shaheen, B. W., & Németh, I. (2022). Integration of maintenance management system functions with Industry 4.0 technologies and features—A review. *Processes*, 10(11), 2173. <https://doi.org/10.3390/pr10112173>

- Sipos, R., Fradkin, D., Moerchen, F., & Wang, Z. (2014). Log-based predictive maintenance. In *Proceedings of the 20th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 1867–1876). <https://doi.org/10.1145/2623330.2623340>
- Sittón-Candanedo, I., Hernández-Nieves, E., Rodríguez, S., Santos-Martín, M. T., & González-Briones, A. (2018). Machine learning predictive model for Industry 4.0. In *13th International Conference, KMO 2018, Žilina, Slovakia, August 6–10, 2018, Proceedings* (pp. 306–317). Springer. https://doi.org/10.1007/978-3-319-95204-8_42
- Taş, Ü. (2024). Advancing predictive maintenance: A comprehensive case study through Industry 4.0. *International Journal of Automotive Engineering and Technologies*, 13(3), 133–142. <https://doi.org/10.18245/ijaet.1543509>
- Wang, J., Ye, L., Gao, R. X., Li, C., & Zhang, L. (2019). Digital twin for rotating machinery fault diagnosis in smart manufacturing. *International Journal of Production Research*, 57(12), 3920–3934. <https://doi.org/10.1080/00207543.2018.1552032>
- Wang, T., Feng, K., Ling, J., Liao, M., Yang, C., Neubeck, R., & Liu, Z. (2024). Pipeline condition monitoring towards digital twin system: A case study. *Journal of Manufacturing Systems*, 73, 256–274. <https://doi.org/10.1016/j.jmsy.2024.02.006>
- Werbińska-Wojciechowska, S., & Winiarska, K. (2023). Maintenance performance in the age of Industry 4.0: A bibliometric performance analysis and a systematic literature review. *Sensors*, 23(3), 1409. <https://doi.org/10.3390/s23031409>
- Yan, J., Meng, Y., Lu, L., & Li, L. (2017). Industrial big data in an Industry 4.0 environment: Challenges, schemes, and applications for predictive maintenance. *IEEE Access*, 5, 23484–23491. <https://doi.org/10.1109/ACCESS.2017.2765544>
- Zhang, J., Wang, Y., Yang, Y., Ma, Y., & Dai, Z. (2024). Fault diagnosis and intelligent maintenance of Industry 4.0 power system based on Internet of Things technology and thermal energy optimization. *Thermal Science and Engineering Progress*, 55, 102902. <https://doi.org/10.1016/j.tsep.2024.102902>

6 Anexo 1: Revisión de plagio

PG2 Jose Alfredo Jimenez Gatica MIIS SCL 2025.docx

 Universidad del Desarrollo

Detalles del documento

Identificador de la entrega

trn:oid:::3117:542559070

Fecha de entrega

21 dic 2025, 3:53 p.m. GMT-3

Fecha de descarga

21 dic 2025, 6:00 p.m. GMT-3

Nombre del archivo

PG2+Jose+Alfredo+Jimenez+Gatica+MIIS+SCL+2025.docx

Tamaño del archivo

766.9 KB

33 páginas

11.379 palabras

70.491 caracteres



Página 1 de 40 - Portada

Identificador de la entrega trn:oid:::3117:542559070



Página 2 de 40 - Descripción general de integridad

Identificador de la entrega trn:oid:::3117:542559070




12% Similitud general

El total combinado de todas las coincidencias, incluidas las fuentes superpuestas, para ca...

Filtrado desde el informe

- ▶ Bibliografía

Fuentes principales

- 10%  Fuentes de Internet
- 3%  Publicaciones
- 10%  Trabajos entregados (trabajos del estudiante)

Marcas de integridad

N.º de alertas de integridad para revisión

Los algoritmos de nuestro sistema analizan un documento en profundidad para buscar inconsistencias que permitirían distinguirlo de una entrega normal. Si advertimos algo extraño, lo marcamos como una alerta para que pueda revisarlo.

Una marca de alerta no es necesariamente un indicador de problemas. Sin embargo, recomendamos que preste atención y la revise.

