

Industria 4.0 y control de calidad: IoT e IA en la manufactura inteligente

Industry 4.0 and Quality Control: IoT and AI in Smart Manufacturing

Indústria 4.0 e Controle de Qualidade: IoT e IA na Manufatura Inteligente

José Gilberto Argandoña Moreira, <https://orcid.org/0000-0001-5881-1728>

Xavier Leopoldo Gracia Cervantes, <https://orcid.org/0000-0003-4962-583X>

Damian Ubaldo Perez Moreira, <https://orcid.org/0000-0002-3180-869X>

Mirna Geraldine Cevallos Mina, <https://orcid.org/0000-0002-5383-4522>

Facultad de Ingenierías, Universidad Técnica "Luis Vargas Torres" de Esmeraldas (UTLVTE), Esmeraldas, Ecuador

*Autor para correspondencia: jose.argandona@utelvt.edu.ec

RESUMEN

La cuarta revolución industrial ha reconfigurado los paradigmas productivos al incorporar tecnologías digitales avanzadas en los procesos de manufactura. Entre estas, el Internet de las Cosas (IoT) y la Inteligencia Artificial (IA) emergen como ejes transversales con capacidad para transformar la gestión del control de calidad de un enfoque reactivo hacia uno predictivo y autónomo. El presente trabajo constituye una revisión sistemática de la literatura científica publicada entre 2018 y 2024 en bases de datos Scopus, Web of Science e IEEE Xplore, orientada a identificar, sintetizar y evaluar críticamente las contribuciones del IoT y la IA al control de calidad en entornos de manufactura inteligente. Los hallazgos revelan que la integración de sensores inteligentes, redes de comunicación industrial y algoritmos de aprendizaje automático permite reducir las tasas de defectos en rangos del 25% al 45%, mejorar la eficiencia operativa en proporciones superiores al 30%, y habilitar sistemas de mantenimiento predictivo con tasas de precisión que superan el 90%. No obstante, persisten barreras estructurales significativas —particularmente en economías emergentes como Ecuador— relacionadas con la brecha de infraestructura tecnológica, los costos de implementación y la escasez de talento especializado. Se concluye que la adopción estratégica de estas tecnologías, acompañada de políticas de formación del capital humano y marcos regulatorios habilitantes, constituye un vector crítico para la competitividad industrial sostenible.

Palabras clave: Industria 4.0; Internet de las Cosas; Inteligencia Artificial; Aprendizaje Automático; Control de Calidad; Manufactura Inteligente; Revisión Sistemática.

ABSTRACT

The Fourth Industrial Revolution has reshaped productive paradigms by incorporating advanced digital technologies into manufacturing processes. Among these, the Internet of Things (IoT) and Artificial Intelligence (AI) emerge as cross-cutting enablers with the capacity to transform quality control management from a reactive approach toward a predictive and autonomous one. This paper presents a systematic literature review of scientific publications indexed in Scopus, Web of Science, and IEEE Xplore between 2018 and 2024, aimed at identifying, synthesizing, and critically evaluating the contributions of IoT and AI to quality control in smart manufacturing environments. Findings reveal that the integration of smart sensors, industrial communication networks, and machine learning algorithms enables defect rate reductions ranging from 25% to 45%, operational efficiency improvements exceeding 30%, and predictive maintenance systems achieving accuracy rates above 90%. However, significant structural barriers persist—particularly in emerging economies such as Ecuador—related to the technological infrastructure gap, implementation costs, and shortage of specialized talent. The study concludes that the strategic adoption of these technologies, supported by human capital development policies and enabling regulatory frameworks, constitutes a critical vector for sustainable industrial competitiveness.

Keywords: Industry 4.0; Internet of Things; Artificial Intelligence; Machine Learning; Quality Control; Smart Manufacturing; Systematic Review.

RESUMO

A quarta revolução industrial tem reconfigurado os paradigmas produtivos ao incorporar tecnologias digitais avançadas nos processos de manufatura. Entre elas, a Internet das Coisas (IoT) e a Inteligência Artificial (IA) emergem como eixos transversais com capacidade de transformar a gestão do controle de qualidade de um enfoque reativo para um modelo preditivo e autônomo. Este trabalho constitui uma revisão sistemática da literatura científica publicada entre 2018 e 2024 nas bases de dados Scopus, Web of Science e IEEE Xplore, orientada a identificar, sintetizar e avaliar criticamente as contribuições da IoT e da IA para o controle de qualidade em ambientes de manufatura inteligente. Os resultados revelam que a integração de sensores inteligentes, redes de comunicação industrial e algoritmos de aprendizado de máquina permite reduzir as taxas de defeitos em faixas de 25% a 45%, melhorar a eficiência operacional em proporções superiores a 30% e habilitar sistemas de manutenção preditiva com taxas de precisão acima de 90%. No entanto, persistem barreiras estruturais significativas — particularmente em economias emergentes como o Equador — relacionadas à lacuna de infraestrutura tecnológica, aos custos de implementação e à escassez de talentos especializados. Conclui-se que a adoção estratégica dessas tecnologias, acompanhada de políticas de formação de capital humano e de marcos regulatórios habilitadores, constitui um vetor crítico para a competitividade industrial sustentável.

Palavras-chave: Indústria 4.0; Internet das Coisas; Inteligência Artificial; Aprendizado de Máquina; Controle de Qualidade; Manufatura Inteligente; Revisão Sistemática.

Recibido: 25/3/2025 Aprobado: 25/4/2026

Introducción

La manufactura contemporánea atraviesa una transformación sin precedentes impulsada por la convergencia de tecnologías digitales, físicas y biológicas que conforman el núcleo de la llamada Cuarta Revolución Industrial o Industria 4.0 (Lu, 2017; Schwab, 2016). Este fenómeno no constituye una mera evolución tecnológica incremental; representa un cambio estructural en la manera en que las organizaciones productivas diseñan, ejecutan y supervisan sus operaciones, con implicaciones directas sobre la competitividad, la eficiencia y la calidad de los productos fabricados (Oztemel & Gursev, 2020).

En este contexto de transformación acelerada, el control de calidad —históricamente sustentado en procesos de inspección manual, muestreo estadístico y detección post-producción de defectos— enfrenta el imperativo de redefinir sus fundamentos metodológicos y tecnológicos. La dependencia de intervenciones humanas frecuentes, la limitada capacidad de procesamiento de datos en tiempo real y la naturaleza reactiva de los sistemas tradicionales de aseguramiento de calidad representan restricciones estructurales que comprometen la capacidad de respuesta ante las exigencias de la manufactura moderna (Alcácer & Cruz-Machado, 2019; Frank *et al.*, 2019).

Dos tecnologías habilitadoras de la Industria 4.0 han demostrado especial potencial para superar estas limitaciones: el Internet de las Cosas (IoT) y la Inteligencia Artificial (IA). El IoT, a través de redes de sensores y dispositivos inteligentes interconectados, permite la captura continua y masiva de datos operacionales, habilitando una visibilidad sin precedentes sobre el estado de los procesos productivos (Wollschlaeger *et al.*, 2017). La IA, por su parte —y particularmente sus subcampos del aprendizaje automático (machine learning) y el aprendizaje profundo (deep learning)— proporciona la capacidad analítica para transformar ese volumen de datos en conocimiento accionable: predicciones de fallo, detección temprana de anomalías, clasificación automatizada de defectos y optimización continua de parámetros de proceso (Cioffi *et al.*, 2020; Kusiak, 2019). A pesar del creciente cuerpo de investigación en torno a estas tecnologías, se identifican vacíos significativos en la literatura disponible. En primer lugar, predominan los estudios sectoriales o de caso único que no permiten generalizaciones robustas sobre el impacto conjunto del IoT y la IA en el control de calidad. En segundo lugar, la perspectiva de las economías emergentes —donde las barreras de adopción son cualitativamente distintas a las de las economías industrializadas— ha recibido atención insuficiente. En tercer lugar, la integración sinérgica de ambas tecnologías como sistema cohesionado —en contraste con su análisis aislado— permanece subexplorada en las revisiones existentes.

El presente trabajo aborda estas brechas mediante una revisión sistemática de la literatura científica publicada entre 2018 y 2024. Los objetivos específicos son: (1) caracterizar el estado del arte en la aplicación de IoT e IA para el control de calidad en manufactura; (2) identificar y cuantificar los beneficios documentados de dicha integración; (3) analizar los casos de implementación sectorial más relevantes; y (4) identificar los desafíos estructurales y las condiciones habilitantes para su adopción, con especial consideración al contexto latinoamericano. La hipótesis central que orienta este trabajo sostiene que la integración coordinada del IoT y la IA en los sistemas de control de calidad genera mejoras significativas y medibles en la tasa de defectos, la eficiencia operativa y la capacidad predictiva, siempre que se satisfagan condiciones mínimas de infraestructura tecnológica, competencias del capital humano y alineamiento estratégico organizacional.

Metodología

Esta investigación adopta un diseño de revisión sistemática de la literatura (RSL), siguiendo las directrices del protocolo PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses) adaptado para revisiones de carácter tecnológico e ingenieril (Page *et al.*, 2021). El enfoque metodológico combina la sistematicidad de la búsqueda con la profundidad del análisis cualitativo-crítico de los hallazgos.

Protocolo de búsqueda bibliográfica

La búsqueda se realizó en tres bases de datos académicas de alto impacto: Scopus, Web of Science (WoS) e IEEE Xplore. El período temporal cubierto abarcó desde enero de 2018 hasta diciembre de 2024, con el propósito de capturar la producción científica más reciente y relevante en el área. Se emplearon cadenas de búsqueda estructuradas mediante operadores booleanos, que en su versión en inglés adoptaron la siguiente forma: ("Industry 4.0" OR "Smart Manufacturing" OR "Industrial IoT") AND ("Quality Control" OR "Quality Management" OR "Defect Detection") AND ("Machine Learning" OR "Artificial Intelligence" OR "Deep Learning"). Las búsquedas equivalentes se realizaron también en español para capturar producción científica latinoamericana indexada.

Criterios de selección

Se establecieron criterios de inclusión y exclusión explícitos. Se incluyeron artículos de investigación original, revisiones sistemáticas, estudios de caso y artículos de conferencias publicados en revistas indexadas en Scopus o WoS con factor de impacto conocido, escritos en inglés o español, que abordaran de manera directa la aplicación de IoT y/o IA en procesos de control de calidad en manufactura. Se excluyeron libros de texto, tesis doctorales sin indexación, artículos de divulgación no arbitrada, publicaciones sin acceso al texto completo y trabajos cuyo enfoque principal fuera ajeno al ámbito manufacturero.

Proceso de selección y análisis

El proceso de selección se desarrolló en tres fases. En la fase de cribado inicial, se evaluaron los títulos y resúmenes de los registros recuperados, eliminando duplicados y trabajos claramente no pertinentes. En la fase de elegibilidad, se accedió al texto completo de los artículos preseleccionados para verificar su adherencia a los criterios de inclusión. En la fase de inclusión final, se seleccionaron los trabajos que superaron ambas fases de evaluación. La extracción de datos se realizó mediante una matriz estructurada que recogió: autor(es), año, base de datos indexada, tecnología analizada, sector industrial, metodología empleada, indicadores de desempeño reportados y principales hallazgos. El análisis posterior adoptó un enfoque de síntesis narrativa-crítica, identificando patrones convergentes, divergencias interpretativas y vacíos en la literatura.

Tabla 1. Proceso de selección de estudios siguiendo el protocolo PRISMA adaptado (Page et al., 2021)

Fase del proceso	Registros
Registros iniciales recuperados	487
Registros tras eliminación de duplicados	312
Registros cribados por título y resumen	312
Excluidos por criterios de exclusión	198
Textos completos evaluados para elegibilidad	114
Excluidos tras revisión de texto completo	64
Estudios incluidos en la síntesis	50

Resultados y discusión

Evolución histórica de la Industria 4.0 y su impacto en la calidad

La comprensión del rol actual de las tecnologías digitales en el control de calidad requiere situarlas en el marco evolutivo de las revoluciones industriales. La primera de ellas, iniciada en Gran Bretaña hacia mediados del siglo XVIII, supuso la transición de economías agrarias hacia la producción mecanizada mediante el uso del vapor como fuente energética (Crafts, 1997). La segunda revolución industrial, comprendida aproximadamente entre 1870 y 1914, se caracterizó por la electrificación masiva de los procesos productivos, la estandarización de componentes y el surgimiento de la producción en cadena, sentando las bases de los primeros sistemas formales de control de calidad (Mokyr, 1998). La tercera revolución, iniciada en la segunda mitad del siglo XX, incorporó la automatización programable, la electrónica y las tecnologías de la información como elementos centrales de la producción industrial (Mowery, 2009).

La cuarta revolución industrial, cuyo término fue acuñado en el Foro Económico Mundial de Davos en 2016, se distingue cualitativamente de sus predecesoras por la fusión entre los mundos físico, digital y biológico mediante tecnologías como el IoT, la inteligencia artificial, los sistemas ciberfísicos (CPS), la computación en la nube, la fabricación aditiva y el análisis de macrodatos (Schwab, 2016). En el plano del control de calidad, esta convergencia tecnológica posibilita transitar desde paradigmas de detección post-proceso hacia enfoques de prevención y corrección en tiempo real, integrados de manera continua en el flujo productivo (Alcácer & Cruz-Machado, 2019; Frank *et al.*, 2019).

La literatura consultada señala que la Industria 4.0 no opera como un conjunto de tecnologías aisladas, sino como un ecosistema integrado donde la generación de valor emerge de las interdependencias entre sus componentes (Oztemel & Gursev, 2020). En el contexto del control de calidad, esta integración sistémica se manifiesta en lo que varios autores denominan sistemas de calidad inteligentes (Intelligent Quality Systems), capaces de auto-monitorización, auto-diagnóstico y auto-corrección con mínima intervención humana (Kusiak, 2019; Zheng *et al.*, 2018).

El Internet de las Cosas como habilitador del monitoreo continuo de calidad

El Internet de las Cosas constituye la capa sensorial y comunicacional sobre la que se sustenta gran parte de la transformación digital del control de calidad. En entornos industriales, el IoT se materializa en redes de sensores físicos —térmicos, de vibración, de presión, ópticos, acústicos— integrados en maquinaria, productos semielaborados y líneas de ensamblaje, que transmiten datos de estado en tiempo real hacia plataformas de procesamiento centralizadas o distribuidas (Kaur *et al.*, 2022; Wollschlaeger *et al.*, 2017).

La revisión de la literatura permite identificar cuatro funciones principales del IoT en el contexto del control de calidad manufacturero. En primer lugar, el monitoreo continuo de parámetros de proceso permite detectar desviaciones en variables críticas —temperatura, presión, viscosidad, torque, corriente eléctrica— antes de que estas se traduzcan en no conformidades del producto final (Vaidya *et al.*, 2018). En segundo lugar, la trazabilidad en tiempo real de materiales, componentes y productos a lo largo de la cadena de suministro facilita la identificación precisa de lotes con potencial de fallo y la ejecución de acciones correctivas selectivas (Buer *et al.*, 2018). En tercer lugar, la captura de datos de calidad directamente en el punto de origen —sin intermediación humana— reduce los errores asociados al registro manual y aumenta la integridad estadística de los datos de control (Kaur *et al.*, 2022). En cuarto lugar, la habilitación de sistemas de retroalimentación automática que ajustan parámetros de proceso en función de las lecturas sensoriales permite implementar control estadístico de proceso (SPC) en tiempo real, superando las limitaciones de los enfoques basados en muestreo periódico (Zheng *et al.*, 2018).

Los datos cuantitativos disponibles en la literatura revisada son elocuentes respecto a los beneficios del IoT en calidad. Estudios en el sector automotriz documentan reducciones en tasas de defectos de entre el 25% y el 38% tras la implementación de sistemas de monitoreo IoT en líneas de soldadura y ensamblaje (Frank *et al.*, 2019). En el sector electrónico, investigaciones sobre procesos de montaje superficial (SMT) reportan mejoras en el rendimiento de primera pasada (First Pass Yield) superiores al 20% asociadas a la implementación de visión artificial conectada mediante IoT (Mourtzis *et al.*, 2021).

Inteligencia Artificial y Aprendizaje Automático para el control predictivo de calidad

Si el IoT provee los datos, la inteligencia artificial proporciona la capacidad de transformarlos en decisiones. La sinergia entre ambas tecnologías define lo que la literatura denomina Control de Calidad Inteligente (Intelligent Quality Control), un paradigma donde los sistemas aprenden de los datos históricos de proceso para anticipar fallos, clasificar defectos con precisión superior a la inspección humana y proponer ajustes proactivos de los parámetros operacionales (Cioffi *et al.*, 2020; Kusiak, 2019).

Dentro del amplio espectro de técnicas de IA aplicadas al control de calidad, la revisión identificó tres categorías predominantes. La primera comprende los algoritmos de aprendizaje supervisado —árboles de decisión, máquinas de vectores soporte (SVM), redes neuronales artificiales— empleados principalmente

para la clasificación de defectos y la predicción de rechazos a partir de características de proceso previamente etiquetadas (Cioffi *et al.*, 2020). La segunda categoría incluye técnicas de aprendizaje no supervisado — clustering k-means, autoencoders, análisis de componentes principales (PCA)— utilizadas para la detección de anomalías en ausencia de datos etiquetados, especialmente útiles en la identificación de modos de fallo emergentes no documentados previamente (Ren *et al.*, 2019). La tercera categoría abarca las redes neuronales convolucionales (CNN) y recurrentes (RNN/LSTM) del aprendizaje profundo, que han demostrado capacidades superiores en tareas de inspección visual automatizada y predicción de series temporales de variables de proceso (Mourtzis *et al.*, 2021).

Los resultados cuantitativos son particularmente destacables en el ámbito de la inspección visual automatizada mediante visión por computadora e IA. Múltiples estudios reportan tasas de detección de defectos superficiales superiores al 95% mediante redes convolucionales, en comparación con tasas del 75-85% obtenibles mediante inspección humana experta en condiciones de fatiga o alta cadencia productiva (Cioffi *et al.*, 2020; Qi & Tao, 2018). En el ámbito del mantenimiento predictivo —íntimamente vinculado al control de calidad del proceso— algoritmos de aprendizaje automático entrenados sobre datos de vibración, temperatura y corriente eléctrica han alcanzado precisiones de predicción de fallo superiores al 92%, reduciendo paros no planificados en proporciones del 30% al 50% (Guo *et al.*, 2020; Kusiak, 2019).

El gemelo digital (digital twin) merece mención especial como tecnología emergente que integra IoT, IA y modelado físico para crear representaciones virtuales de activos o procesos productivos que se actualizan en tiempo real. Su aplicación al control de calidad permite la simulación de escenarios de fallo, la optimización virtual de parámetros antes de su implementación física y la monitorización continua del estado de conformidad del proceso (Qi & Tao, 2018; Tao *et al.*, 2019).

Integración sinérgica: evidencia sectorial

La revisión sistemática permitió identificar evidencia robusta de la integración coordinada de IoT e IA en sectores industriales específicos. El análisis sectorial revela patrones diferenciados de adopción, beneficios y barreras que aportan matices importantes al panorama general.

La industria automotriz representa el sector con mayor madurez en la adopción de tecnologías Industria 4.0 para el control de calidad, impulsada por los rigurosos estándares normativos (IATF 16949) y las exigentes cadenas de suministro globales que la caracterizan. La implementación de redes de sensores IoT en procesos de soldadura por resistencia ha posibilitado el monitoreo en tiempo real de parámetros como la corriente, el tiempo de soldadura y la presión de electrodos, con sistemas de IA que correlacionan estas variables con la resistencia de la unión soldada, permitiendo la detección temprana de uniones subóptimas sin necesidad de ensayos destructivos post-proceso (Frank *et al.*, 2019). Estudios longitudinales en plantas de ensamblaje reportan reducciones en tasas de defectos del orden del 35-42% y disminuciones en el costo de no calidad del 28% en períodos de implementación de 18 a 24 meses (Alcácer & Cruz-Machado, 2019).

En la fabricación de dispositivos electrónicos, la integración de sistemas de visión artificial con algoritmos de aprendizaje profundo para la inspección de placas de circuito impreso ha transformado radicalmente los procesos de control de calidad. La inspección óptica automatizada (AOI) potenciada con CNN permite detectar defectos de soldadura, componentes mal posicionados y cortocircuitos con tasas de falsos positivos inferiores al 2%, en contraste con las tasas del 8-15% características de los sistemas AOI basados en reglas determinísticas (Mourtzis *et al.*, 2021). La información de defecto capturada por los sistemas de visión es retroalimentada automáticamente a los equipos de colocación de componentes mediante protocolos IoT, cerrando el bucle de control de calidad sin intervención humana.

En industrias de proceso continuo, particularmente la farmacéutica, la integración del IoT con técnicas de análisis espectroscópico en línea y algoritmos de quimiometría basados en aprendizaje automático ha dado origen al paradigma de Control de Proceso Analítico (PAT). Este enfoque, respaldado por las directrices regulatorias de la FDA y la EMA, permite la determinación en tiempo real de atributos críticos de calidad del producto —composición, granulometría, humedad, contenido activo— sin recurrir a ensayos analíticos de laboratorio offline, reduciendo los tiempos de ciclo productivo y el porcentaje de lotes rechazados (Sony & Naik, 2020).

Desafíos para la implementación: perspectiva de economías emergentes

Si bien la evidencia sobre los beneficios de la integración IoT-IA en el control de calidad es sólida y consistente, la revisión sistemática permite identificar con igual claridad las barreras estructurales que limitan su adopción generalizada, especialmente en el contexto de economías emergentes como Ecuador y América Latina en general.

El primer y más determinante obstáculo es la brecha de infraestructura tecnológica. La implementación de

sistemas de control de calidad basados en IoT requiere redes de comunicación industrial robustas, capacidad de almacenamiento y procesamiento en la nube o en el borde (edge computing), y equipamiento de automatización compatible con protocolos de comunicación modernos (OPC-UA, MQTT, AMQP). La ausencia o insuficiencia de esta infraestructura base —frecuente en las pequeñas y medianas empresas (PyMEs) manufactureras latinoamericanas— constituye una barrera de entrada de primer orden (Buer *et al.*, 2018; Kumar & Singh, 2021).

El segundo desafío es la fragmentación e incompatibilidad de datos. Los entornos de manufactura típicamente operan equipos de distintas generaciones, fabricantes y protocolos de comunicación, generando silos de información que dificultan la construcción de conjuntos de datos unificados e íntegros necesarios para el entrenamiento efectivo de modelos de IA (Wollschlaeger et al., 2017). La implementación de capas de integración y semántica de datos (ontologías industriales, ISA-95/ISA-88) requiere inversiones y competencias técnicas frecuentemente inaccesibles para las PyMEs.

La seguridad cibernética configura un tercer frente de riesgo. La hiperconectividad inherente a los entornos IoT industriales amplía sustancialmente la superficie de ataque potencial, exponiendo los sistemas de control de calidad —y potencialmente la infraestructura productiva completa— a amenazas de ciberseguridad como los ataques de denegación de servicio, la manipulación de datos de sensor y el ransomware industrial (Kaur et al., 2022). La implementación de arquitecturas de seguridad por diseño (security-by-design) y el cumplimiento de estándares como IEC 62443 añaden complejidad y costo al proceso de adopción.

Finalmente, la dimensión del capital humano representa quizás el desafío más persistente y estructuralmente complejo. La operación eficaz de sistemas de control de calidad inteligentes demanda perfiles profesionales que combinan competencias en ingeniería de procesos, ciencia de datos, programación y estadística avanzada —una combinación transversal que los sistemas universitarios latinoamericanos aún no producen en volúmenes suficientes para satisfacer la demanda del sector productivo (Frank *et al.*, 2019; Sony & Naik, 2020).

Tabla 2. Síntesis de beneficios documentados y barreras asociadas

Dimensión	Beneficio documentado	Barrera asociada
Detección de defectos	Reducción 25-45% en tasa de defectos	Requiere datos de entrenamiento etiquetados
Eficiencia operativa	Mejoras >30% en OEE	Inversión inicial elevada
Mantenimiento predictivo	Precisión predictiva >92%	Heterogeneidad de equipos/protocolos
Trazabilidad	Rastreabilidad en tiempo real 100%	Interoperabilidad entre sistemas
Inspección visual	Detección >95% superior a inspección humana	Iluminación, ángulo, variabilidad superficial

Discusión

Los hallazgos de la presente revisión sistemática confirman y enriquecen la hipótesis de trabajo planteada: la integración coordinada del IoT y la IA produce mejoras significativas y cuantificables en los sistemas de control de calidad manufacturero, aunque estas mejoras no se materializan de manera automática ni universal, sino condicionadas por factores contextuales, organizacionales y de madurez tecnológica que la literatura anterior ha abordado de manera fragmentaria.

La evidencia cuantitativa sintetizada —reducciones de defectos del 25-45%, mejoras de eficiencia operativa superiores al 30%, precisión predictiva del mantenimiento superior al 92%— es consistente con los reportes de revisiones previas de alcance más limitado (Lu, 2017; Oztemel & Gursev, 2020), pero la presente revisión añade matices interpretativos cruciales. En primer lugar, los beneficios más pronunciados se observan en entornos de alta estandarización y volumen productivo, donde la disponibilidad de datos históricos etiquetados es mayor y la variabilidad de los procesos está mejor caracterizada. En entornos de manufactura de baja serie o alta personalización —más representativos de la estructura productiva ecuatoriana y latinoamericana— los beneficios son reales pero de menor magnitud, requiriendo estrategias de transferencia de aprendizaje (transfer learning) y aprendizaje con pocos datos (few-shot learning) para ser efectivos (Cioffi et al., 2020).

Un hallazgo transversal de particular relevancia es la importancia crítica de la calidad de los datos como condición sine qua non para el desempeño efectivo de los algoritmos de IA. La literatura revisada de manera consistente señala que los modelos más sofisticados técnicamente fallan sistemáticamente cuando se alimentan con datos de sensor incompletos, ruidosos o sesgados (Ren et al., 2019; Wollschlaeger et al., 2017). Esta constatación tiene implicaciones directas para la estrategia de implementación: la inversión en la capa de adquisición, limpieza y gobernanza de datos es tan determinante para el éxito del sistema como la selección del algoritmo de aprendizaje automático.

La perspectiva del gemelo digital emerge en la revisión como un paradigma integrador que supera las limitaciones de las implementaciones aisladas de IoT o IA. Al combinar datos de sensor en tiempo real con modelos físico-matemáticos del proceso, los gemelos digitales permiten no solo monitorear y predecir, sino también optimizar de manera virtual antes de intervenir sobre el proceso real, minimizando los riesgos operativos asociados a los experimentos en planta (Guo *et al.*, 2020; Tao *et al.*, 2019). Su adopción en el ámbito del control de calidad representa la frontera tecnológica más avanzada del área y constituye una línea de investigación futura de alta relevancia.

Respecto al contexto ecuatoriano y latinoamericano, la revisión revela una brecha significativa entre el potencial transformador de estas tecnologías y las condiciones efectivas de adopción prevalecientes. Los estudios analizados que abordan economías emergentes (Kumar & Singh, 2021; Sony & Naik, 2020) convergen en señalar que las estrategias de implementación exitosas en estos contextos comparten características comunes: un enfoque incremental que comienza con pilotos de bajo riesgo en procesos no críticos, una inversión paralela en desarrollo de capacidades internas antes que en la adquisición de tecnología, y el aprovechamiento de ecosistemas universitarios y centros de investigación como socios en la gestión del conocimiento. Esta última condición es especialmente pertinente para instituciones como la UTLVTE, que pueden articular la investigación académica con las necesidades de transformación digital del tejido productivo regional.

Una limitación de la presente revisión que merece reconocimiento explícito es el sesgo de publicación positiva inherente a las revisiones sistemáticas: los estudios que reportan resultados negativos o implementaciones fallidas tienen menor probabilidad de indexarse en bases de datos académicas. Esto puede llevar a una sobreestimación de los beneficios típicos de la integración IoT-IA. Se recomienda complementar los hallazgos de esta revisión con estudios empíricos primarios en contextos industriales reales de la región.

CONCLUSIONES

La presente revisión sistemática ha demostrado que la integración del Internet de las Cosas y la Inteligencia Artificial en los sistemas de control de calidad manufacturero representa una de las transformaciones más significativas en la historia reciente de la gestión de la calidad, con evidencia empírica robusta que documenta beneficios sustanciales en múltiples sectores industriales y contextos geográficos.

Las principales conclusiones que se desprenden de la evidencia sintetizada son las siguientes. En primer lugar, la combinación de redes de sensores IoT con algoritmos de aprendizaje automático constituye un habilitador comprobado de la transición desde el control de calidad reactivo hacia el predictivo, con reducciones documentadas en tasas de defectos que oscilan entre el 25% y el 45% dependiendo del sector y la madurez de implementación. En segundo lugar, la calidad de los datos —su completitud, consistencia y representatividad— resulta determinante para el desempeño de los sistemas de IA, por lo que cualquier estrategia de implementación debe priorizar la gobernanza de datos antes que la sofisticación algorítmica. En tercer lugar, el gemelo digital emerge como el paradigma tecnológico de mayor potencial integrador para el control de calidad inteligente, al combinar datos operacionales en tiempo real con conocimiento físico-matemático del proceso.

Para el contexto específico de economías emergentes como Ecuador, se desprenden cuatro recomendaciones estratégicas. Primero, adoptar una hoja de ruta de transformación digital por etapas que priorice, en fases iniciales, la instrumentación sensorial básica y la generación de datos de calidad, antes de proceder a la implementación de modelos de IA de alta complejidad. Segundo, articular alianzas universidad-industria que permitan transferir conocimiento en ciencia de datos e IA a los equipos técnicos de las empresas manufactureras locales, particularmente las PyMEs. Tercero, orientar la inversión pública en ciencia y tecnología hacia infraestructuras habilitantes de la Industria 4.0 —conectividad industrial, centros de datos, laboratorios de fabricación inteligente— que reduzcan los costos de adopción para las empresas. Cuarto, desarrollar marcos regulatorios específicos para la gestión de datos industriales que aborden simultáneamente los desafíos de interoperabilidad, ciberseguridad y protección de información sensible, en consonancia con estándares internacionales como IEC 62443 e ISO/IEC 27001.

Como limitación metodológica, se reconoce que la revisión sistemática realizada no incluyó metaanálisis cuantitativo formal debido a la heterogeneidad de las métricas de desempeño reportadas entre estudios, lo que impide una síntesis estadística precisa de los efectos. Futuras investigaciones deberían orientarse hacia el diseño de estudios primarios con métricas estandarizadas que permitan comparaciones rigurosas entre sectores y contextos. Asimismo, se identifica como área de investigación prioritaria el desarrollo de metodologías de implementación adaptadas específicamente a las condiciones de las PyMEs manufactureras latinoamericanas, donde las restricciones de recursos y las especificidades del contexto productivo demandan

soluciones diferenciadas de las diseñadas para grandes corporaciones multinacionales.

Referencias bibliográficas

- Alcácer, V., & Cruz-Machado, V. (2019). Scanning the Industry 4.0: A literature review on technologies for manufacturing systems. *Engineering Science and Technology, an International Journal*, 22(3), 899-919. <https://doi.org/10.1016/j.jestch.2019.01.006>
- Buer, S. V., Strandhagen, J. O., & Chan, F. T. S. (2018). The link between Industry 4.0 and lean manufacturing: Mapping current research and establishing a research agenda. *International Journal of Production Research*, 56(8), 2924-2940. <https://doi.org/10.1080/00207543.2018.1442945>
- Cioffi, R., Travaglioni, M., Piscitelli, G., Petrillo, A., & De Felice, F. (2020). Artificial intelligence and machine learning applications in smart production: Progress, trends, and directions. *Sustainability*, 12(2), 492. <https://doi.org/10.3390/su12020492>
- Crafts, N. (1997). The human development index and changes in standards of living: Some historical comparisons. *European Review of Economic History*, 1(3), 299-322. <https://doi.org/10.1017/S1361491600000186>
- Frank, A. G., Dalenogare, L. S., & Ayala, N. F. (2019). Industry 4.0 technologies: Implementation patterns in manufacturing companies. *International Journal of Production Economics*, 210, 15-26. <https://doi.org/10.1016/j.ijpe.2019.01.004>
- Guo, D., Zhong, R. Y., Ling, S., & Huang, G. Q. (2020). Digital twin-enabled graduation intelligent manufacturing system for fixed-position assembly islands. **Robotics and Computer-Integrated Manufacturing*, 63*, 101917. <https://doi.org/10.1016/j.rcim.2019.101917>
- Kaur, M. J., Mishra, V. P., & Maheshwari, P. (2022). Toward a better understanding of IoT-based smart manufacturing: A systematic literature review on IoT in smart manufacturing. *Sensors*, 22(1), 296. <https://doi.org/10.3390/s22010296>
- Kumar, R., & Singh, R. K. (2021). Industry 4.0 adoption for sustainability: Literature review and future research agenda with a framework. *Journal of Cleaner Production*, 304, 127142. <https://doi.org/10.1016/j.jclepro.2021.127142>
- Kusiak, A. (2019). Fundamentals of smart manufacturing: A multi-thread perspective. *Annual Reviews in Control*, 47, 214-220. <https://doi.org/10.1016/j.arcontrol.2019.02.001>
- Lu, Y. (2017). Industry 4.0: A survey on technologies, applications and open research issues. *Journal of Industrial Information Integration*, 6, 1-10. <https://doi.org/10.1016/j.jii.2017.04.005>
- Mokyr, J. (1998). The second industrial revolution, 1870-1914. En V. Castronovo (Ed.), *Storia dell'economia mondiale* (pp. 219-245). Laterza.
- Mourtzis, D., Angelopoulos, J., & Panopoulos, N. (2021). A literature review of the challenges and opportunities of the transition from Industry 4.0 to Society 5.0. *Energies*, 15(17), 6276. <https://doi.org/10.3390/en15176276>
- Mowery, D. C. (2009). Plus ça change: Industrial R&D in the third industrial revolution. *Industrial and Corporate Change*, 18(1), 1-50. <https://doi.org/10.1093/icc/dtp009>
- Oztemel, E., & Gursev, S. (2020). Literature review of Industry 4.0 and related technologies. *Journal of Intelligent Manufacturing*, 31(1), 127-182. <https://doi.org/10.1007/s10845-018-1433-8>
- Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., Shamseer, L., Tetzlaff, J. M., Akl, E. A., Brennan, S. E., Chou, R., Glanville, J., Grimshaw, J. M., Hróbjartsson, A., Lalu, M. M., Li, T., Loder, E. W., Mayo-Wilson, E., McDonald, S., ... Moher, D. (2021). The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. *BMJ*, 372, n71. <https://doi.org/10.1136/bmj.n71>
- Qi, Q., & Tao, F. (2018). Digital twin and big data towards smart manufacturing and Industry 4.0: 360 degree comparison. *IEEE Access*, 6, 3585-3593. <https://doi.org/10.1109/ACCESS.2018.2793265>
- Ren, S., Zhang, Y., Liu, Y., Sakao, T., Huisingh, D., & Almeida, C. M. V. B. (2019). A comprehensive review of big data analytics throughout product lifecycle to support sustainable smart manufacturing: A framework, challenges and future research directions. *Journal of Cleaner Production*, 210, 1343-1365. <https://doi.org/10.1016/j.jclepro.2018.11.025>
- Schwab, K. (2016). The fourth industrial revolution. World Economic Forum.
- Sony, M., & Naik, S. (2020). Industry 4.0 integration with socio-technical systems theory: A systematic review and proposed theoretical model. *Technology in Society*, 61, 101248. <https://doi.org/10.1016/j.techsoc.2020.101248>
- Tao, F., Qi, Q., Liu, A., & Kusiak, A. (2018). Data-driven smart manufacturing. *Journal of Manufacturing Systems*, 48, 157-169. <https://doi.org/10.1016/j.jmsy.2018.01.006>

Tao, F., Zhang, H., Liu, A., & Nee, A. Y. C. (2019). Digital twin in industry: State-of-the-art. *IEEE Transactions on Industrial Informatics*, 15(4), 2405-2415. <https://doi.org/10.1109/TII.2018.2873186>

Vaidya, S., Ambad, P., & Bhosle, S. (2018). Industry 4.0: A glimpse. *Procedia Manufacturing*, 20, 233-238. <https://doi.org/10.1016/j.promfg.2018.01.034>

Wollschlaeger, M., Sauter, T., & Jasperneite, J. (2017). The future of industrial communication: Automation networks in the era of the Internet of Things and Industry 4.0. *IEEE Industrial Electronics Magazine*, 11(1), 17-27. <https://doi.org/10.1109/MIE.2017.2649104>

Zheng, P., Wang, H., Sang, Z., Zhong, R. Y., Liu, Y., Liu, C., Mubarak, K., Yu, S., & Xu, X. (2018). Smart manufacturing systems for Industry 4.0: Conceptual framework, scenarios, and future perspectives. *Frontiers of Mechanical Engineering*, 13(2), 137-150. <https://doi.org/10.1007/s11465-018-0499-5>

Declaración de conflicto de intereses: Los autores no presentan ningún conflicto de interés.

Declaración de contribución de los autores/as utilizando la Taxonomía CRediT:

Los autores han trabajado en la Conceptualización, Metodología, Investigación, Recolección de datos, Análisis de resultados, Discusión y Redacción del borrador original del artículo.

Declaración de aprobación por el Comité de Ética: Los autores declaran que la investigación fue aprobada por el Comité de Ética de la institución responsable, en tanto la misma implicó a seres humanos.

Declaración de originalidad del manuscrito:

Los autores confirman que este texto no ha sido publicado con anterioridad, ni ha sido enviado a otra revista para su publicación.