

A Systematic Literature Review: Advances and Challenges of Generative Artificial Intelligence in Engineering

Pérez-Samanamud, Miguel V., Doctor¹, Pérez-Samanamud, Manuel E., Doctor¹, Pérez-Guevara, Luciano, Doctor¹, Cruz-Vargas, Rosa M., Doctora¹

¹Universidad Nacional Federico Villarreal, Perú, mperezsa@unfv.edu.pe, mperez@unfv.edu.pe, lperezg@unfv.edu.pe, 2016008905@unfv.edu.pe

Abstract– This systematic literature review examines the advances and challenges of Generative Artificial Intelligence (GenAI) in engineering using the PICOC strategy and strictly following PRISMA 2020 guidelines to ensure transparency, reproducibility, and methodological rigor. The search conducted in Scopus (2023–2026) initially identified 24,166 records, which were filtered through predefined inclusion and exclusion criteria, resulting in a final sample of 98 studies. Findings indicate that GenAI applications are predominantly concentrated in industrial and chemical process optimization (59.7%), followed by generative design and simulation (19.4%), predictive maintenance (6.2%), and telecommunications (5.4%). Heuristic optimizers dominate methodological approaches (90.7%), complemented by advanced generative models (76.7%), Deep Learning (34.1%), and traditional Machine Learning (27.9%). Only 60.5% of the studies report experimental comparisons, revealing gaps in methodological standardization. Reported performance improvements include efficiency gains (54.3%), productivity increases (24%), and enhanced reliability (14%). Validation practices rely primarily on statistical cross-validation (91.5%) and real-world industrial testing (59.7%). However, persistent limitations involve data scarcity (23.3%) and high computational costs (14%). Overall, the evidence confirms that GenAI is emerging as a strategic technology for addressing complex engineering problems, although broader industrial validation frameworks and standardized evaluation metrics remain necessary to ensure scalable and sustainable adoption.

Keywords-- Generative Artificial Intelligence, Engineering Optimization, Deep Learning Techniques, Predictive Maintenance, and Industrial Automation

Una Revisión Sistemática de la Literatura: Avances y Retos de la Inteligencia Artificial Generativa en Ingeniería

Pérez-Samanamud, Miguel V., Doctor¹, Pérez-Samanamud, Manuel E., Doctor¹, Pérez-Guevara, Luciano, Doctor¹, y Cruz-Vargas, Rosa M., Doctora¹

¹Universidad Nacional Federico Villarreal, Perú, mperezs@unfv.edu.pe, mperez@unfv.edu.pe, lperezg@unfv.edu.pe, 2016008905@unfv.edu.pe

Resumen— Esta revisión sistemática analiza los avances y retos de la Inteligencia Artificial Generativa (IAG) en ingeniería mediante la estrategia PICOC y siguiendo rigurosamente las directrices PRISMA 2020. La búsqueda en Scopus (2023–2026) arrojó 24.166 registros iniciales que, tras aplicar criterios de inclusión y exclusión, se depuraron hasta una muestra final de 98 estudios. Los resultados muestran que la IAG se concentra principalmente en optimización de procesos industriales y químicos (59.7%), seguida de diseño generativo y simulación (19.4%), mantenimiento predictivo (6.2%) y telecomunicaciones (5.4%). Metodológicamente, predominan optimizadores heurísticos (90.7%), complementados por modelos generativos avanzados (76.7%), Deep Learning (34.1%) y Machine Learning tradicional (27.9%). Solo el 60.5% de los estudios realiza comparaciones experimentales, evidenciando brechas en estandarización. Se reportan mejoras en eficiencia (54.3%), productividad (24%) y confiabilidad (14%), mientras que la validación se basa principalmente en validación cruzada (91.5%) y pruebas en entornos reales (59.7%). No obstante, persisten limitaciones asociadas a insuficiencia de datos (23.3%) y altos costos computacionales (14%). La evidencia confirma que la IAG emerge como tecnología estratégica para resolver problemas complejos en ingeniería, aunque requiere marcos robustos de evaluación, mayor validación industrial y estandarización de métricas para consolidar su adopción sostenible.

Palabras clave— Inteligencia Artificial Generativa, Optimización en Ingeniería, Técnicas de Deep Learning, Mantenimiento Predictivo, y Automatización Industrial

I. INTRODUCCIÓN

Durante el último quinquenio, la Inteligencia Artificial (IA) se ha consolidado como un motor clave de transformación científica y tecnológica, destacando la emergencia de la Inteligencia Artificial Generativa (IAG), caracterizada por su capacidad de producir y optimizar soluciones a partir de grandes volúmenes de datos, ampliando su aplicación en la ingeniería moderna [1].

A nivel internacional, la IAG ha generado impactos transversales en diversos dominios. En optimización industrial, los algoritmos metaheurísticos han permitido resolver problemas complejos de diseño [1] mientras que en telecomunicaciones, los modelos aplicados a redes 5G y 6G han optimizado la asignación de recursos y reducido latencias [2]. En el ámbito aeroespacial, el procesamiento inteligente de datos satelitales ha mejorado la observación terrestre y la planificación ambiental [3]. Asimismo, en manufactura avanzada, los modelos generativos han optimizado el consumo

energético en industrias como la de semiconductores [4]. y enfoques basados en aprendizaje por refuerzo en redes IoT han contribuido a mejorar la eficiencia y sostenibilidad operativa [5].

El desarrollo de modelos de lenguaje de gran escala (LLM) ha extendido el uso de la IAG hacia la documentación técnica y la toma de decisiones [6]. Sin embargo, también ha incrementado riesgos de ciberseguridad, impulsando soluciones basadas en IA en arquitecturas SDN [7].

En América Latina, la adopción de la IAG es creciente pero heterogénea, con aplicaciones en agricultura, logística y energía en países como Brasil y México [8],[9] así como en monitoreo ambiental en Argentina y Chile [9], evidenciando una convergencia progresiva con tendencias globales [10].

En Perú, su implementación se concentra en iniciativas académicas y proyectos piloto, con aplicaciones en simulación sísmica [11], diseño mecánico [12] y sistemas informáticos

[12], aunque limitada por brechas en inversión, formación e infraestructura tecnológica [13],[14]. Estos factores condicionan la capacidad del Perú para competir en igualdad de condiciones en el escenario global de la inteligencia artificial.

Los avances identificados en la literatura pueden agruparse en Los avances identificados se agrupan en cuatro dimensiones: optimización industrial, diseño generativo, mantenimiento predictivo e inteligencia operativa, y sostenibilidad energética, evidenciando una transformación en la lógica de diseño y toma de decisiones en ingeniería.

A pesar de su expansión acelerada, la adopción de la IAG enfrenta desafíos significativos. Entre ellos destacan la interpretabilidad de modelos complejos [15],[16], riesgos de ciberseguridad [7], [17], elevado consumo energético en el entrenamiento de modelos de gran escala [16],[18], brechas tecnológicas en economías emergentes [19], y ausencia de marcos regulatorios estandarizados [20]. Estas tensiones configuran un escenario donde el potencial transformador de la IAG coexiste con exigencias críticas de gobernanza, ética y sostenibilidad [21], [22], [23], [24].

En este contexto, se hace necesaria una revisión sistemática que permita sintetizar evidencia empírica reciente, identificar tendencias cuantificables y analizar brechas metodológicas en la aplicación de la IAG en ingeniería, proporcionando así una base rigurosa para futuras investigaciones y desarrollos industriales.

II. MÉTODO

La presente investigación adoptó un diseño de Revisión Sistemática de Literatura (RSL) estructurado bajo los lineamientos del estándar internacional PRISMA 2020, garantizando transparencia, trazabilidad y reproducibilidad en cada fase del proceso. Con el propósito de delimitar rigurosamente el objeto de estudio, se empleó la estrategia PICOC, la cual permitió operacionalizar los componentes conceptuales de la revisión. (Ver Tabla I y II)

TABLA I
COMPONENTES DEL PICO

Componentes del PICO	
Componente	Descripción
P(Problema)	Optimización de procesos
I(intervención)	Inteligencia artificial generativa
C(Comparación)	En el estudio no se hizo comparación
O(Resultados)	Mejora de la productividad
C(Contexto)	IAG aplicado en la ingeniería

En esa línea de ideas se plantea la pregunta general de investigación (RQ): ¿De qué manera la Inteligencia Artificial Generativa (IAG) interviene en la resolución de problemáticas propias de la ingeniería, potenciando la automatización de procesos, el análisis avanzado de datos y el diseño de soluciones técnicas, en contraste con enfoques tradicionales o metodologías convencionales?

Asimismo, se plantean las preguntas secundarias:

RQ1: ¿Cuáles son las problemáticas específicas abordadas mediante la aplicación de IAG en las distintas especialidades de la ingeniería?

RQ2: ¿Qué arquitecturas, modelos y técnicas de IAG se implementan para enfrentar desafíos relacionados con automatización, optimización o diseño en entornos ingenieriles?

RQ3: ¿Cómo se desempeñan las soluciones fundamentadas en IAG frente a métodos tradicionales o enfoques de inteligencia artificial no generativa en términos de precisión, eficacia y rendimiento operativo?

RQ4: ¿Qué evidencias empíricas reportan mejoras en productividad, eficiencia y confiabilidad tras la incorporación de IAG en la solución de problemas de ingeniería?

RQ5: ¿Cuáles son los mecanismos de validación utilizados para evaluar soluciones basadas en IAG en contextos industriales y qué limitaciones, riesgos o restricciones metodológicas se identifican en su implementación?

La recolección de información se realizó exclusivamente en la base de datos **Scopus**, debido a su cobertura multidisciplinaria y estándares de indexación. Se construyó una ecuación de búsqueda combinando términos en inglés asociados a ingeniería, modelos generativos, productividad y contextos industriales, utilizando operadores booleanos AND/OR aplicados a los campos TITLE-ABS-KEY.

TABLA II
PALABRAS CLAVE

Componente	Palabras claves (Español)	Palabras claves ingles
P (Población /problemas)	Problemas en ingeniería, optimización de procesos, ingeniería de sistemas, mecatrónica, electrónica, telecomunicaciones	Engineering Problems, Process Optimization, Systems Engineering, Mechatronics, Electronics, Telecommunications
I Intervención	Inteligencia artificial generativa, solución de problemas, modelos de lenguaje, GAN, Transformers, stable diffusion	Generative Artificial Intelligence, Problem-Solving, Language Models, Generative Adversarial Networks (GANs), Transformers, Stable Diffusion
O Resultados	Productividad, eficiencia, optimización, confiabilidad, innovación tecnológica	Productivity, Efficiency, Optimization, Reliability, Technological Innovation
C Contextos	IAG aplicado en la ingeniería	AIG applied in engineering

Siguiendo el patrón de la tabla II se construye el siguiente Query:

(TITLE-ABS-KEY ("Engineering Problems" OR "Process Optimization" OR "Systems Engineering" OR "Mechatronics" OR "Electronics" OR "Telecommunications" OR "Engineering Applications"))

AND ("Generative Artificial Intelligence" OR "Generative AI" OR "Language Models" OR "Generative Adversarial Networks" OR "GAN" OR "Transformers" OR "Stable Diffusion" OR "Generative Models")

AND (Productivity OR Efficiency OR Optimization OR Reliability OR "Technological Innovation" OR Automation OR "Engineering Solutions")

AND ("Industrial Settings" OR "Industry" OR "Engineering Education" OR "Applied Research" OR "Engineering Practice")

Una vez establecida la ecuación de búsqueda, se procedió a la extracción sistemática de registros en la base de datos Scopus. La ejecución de dicha estrategia produjo un volumen considerable de referencias iniciales. No obstante, tras una revisión preliminar, se identificó que una proporción relevante de los documentos recuperados no guardaba correspondencia directa con el propósito específico de la investigación. En consecuencia, se aplicó un proceso de filtrado fundamentado en criterios estrictos de inclusión y exclusión, con el objetivo de depurar el corpus bibliográfico y conservar exclusivamente aquellos estudios alineados con el enfoque temático y metodológico de la revisión.

TABLA III
CRITERIOS DE INCLUSIÓN Y EXCLUSIÓN

Código	Tipo	Criterio priorizado
CI1	Inclusión	Publicaciones 2023–2026, centradas en IA generativa (ej. GPT-3, GPT-4 y posteriores).
CI2	Inclusión	Artículos en inglés para asegurar consistencia en el

		análisis.
CI3	Inclusión	Estudios experimentales, cuasiexperimentales, casos o revisiones sistemáticas con evidencia empírica.
CI4	Inclusión	Investigaciones que evalúan impacto, eficacia o desempeño de IA generativa en ingeniería.
CI5	Inclusión	Acceso a texto completo (abierto o institucional).
CE1	Exclusión	Registros duplicados o con información incompleta (sin DOI, autores, año o resultados).
CE2	Exclusión	Publicaciones en idiomas distintos al inglés.
CE3	Exclusión	Opiniones, editoriales o revisiones narrativas sin evidencia empírica.
CE4	Exclusión	Estudios sin datos verificables (cuantitativos o cualitativos).
CE5	Exclusión	Trabajos no relacionados directamente con IA generativa.

Asimismo, la estrategia de búsqueda se ejecutó de manera exclusiva en la base de datos Scopus, seleccionada por su amplia cobertura multidisciplinaria, estándares de indexación rigurosos y reconocimiento internacional en la comunidad científica. La aplicación de la ecuación de búsqueda general permitió recuperar un total inicial de 24.166 registros, lo que evidencia la amplitud temática y la creciente producción científica relacionada con inteligencia artificial y aplicaciones en ingeniería. Es relevante señalar que, durante esta fase preliminar, no se identificaron documentos duplicados dentro del conjunto recuperado, lo cual facilitó la depuración inicial del corpus.

Posteriormente, se aplicó un primer filtro cronológico delimitando el periodo de publicación entre los años 2023 y 2026, con el propósito de capturar evidencia reciente vinculada al auge contemporáneo de la Inteligencia Artificial Generativa. Esta restricción temporal redujo el conjunto a 1,096 documentos, consolidando una base alineada con la evolución más reciente del campo.

En una segunda etapa, se procedió a restringir la búsqueda a las áreas temáticas directamente relacionadas con ingeniería e informática, lo que permitió focalizar el análisis en contextos estrictamente técnicos y aplicados, obteniendo 845 registros. Posteriormente, la selección se limitó exclusivamente a artículos científicos, excluyendo otros tipos documentales, lo que redujo el número a 745 estudios.

La aplicación de filtros adicionales basados en palabras clave específicas vinculadas a la IAG permitió disminuir la muestra a 560 documentos. A continuación, el criterio idiomático (inglés) consolidó 484 registros, asegurando coherencia lingüística en el análisis. De este conjunto, se priorizaron 197 artículos en acceso abierto, los cuales fueron sometidos a revisión exhaustiva de contenido. Finalmente, tras aplicar rigurosamente los criterios de exclusión y realizar una evaluación detallada de pertinencia temática y calidad metodológica, se estableció una muestra definitiva de 98 estudios, que constituyen la base analítica de la presente Revisión Sistemática de Literatura.




Fig. 1 Diagrama de flujo PRISMA del proceso de selección de literatura en este estudio

III. RESULTADOS

A) Resultados bibliométricos

El análisis bibliométrico se fundamentó en una depuración temática estrictamente circunscrita a las áreas de ingeniería e informática dentro de Scopus, lo que permitió consolidar un universo inicial de 845 documentos pertinentes. Al examinar la distribución temporal entre 2023 y 2026, se identifica una tendencia ascendente en la producción científica, coherente con la rápida consolidación de la Inteligencia Artificial Generativa como tecnología emergente en entornos ingenieriles. La producción alcanza su punto máximo en 2025 con 41 publicaciones, evidenciando el mayor nivel de madurez investigativa durante el periodo analizado, mientras que en 2026 se registran 2 estudios, cifra atribuible al carácter parcial del año en el momento de la recopilación. La progresión observada desde 2023 confirma un crecimiento sostenido del interés académico y técnico en la IAG aplicada a ingeniería, posicionándola como un eje estratégico de investigación contemporánea.




Fig. 2 Cantidad de artículos por años

a) Artículos publicados por países

El análisis geográfico de la producción científica revela que los 98 estudios seleccionados se distribuyen en 51 países durante el periodo 2023–2026, lo que evidencia una expansión global del interés por la Inteligencia Artificial Generativa en ingeniería. China lidera de manera significativa la contribución académica con 29 publicaciones (29.59%), consolidándose como el principal polo de investigación en el área. En un segundo nivel se ubican Alemania y España, con 9 estudios cada uno (9.18%), seguidas por el Reino Unido con 8 publicaciones (8.16%). Asimismo, India y Corea del Sur registran 7 estudios cada uno (7.14%), reflejando una participación relevante dentro del escenario asiático y europeo. El conjunto restante de países aporta entre uno y cinco estudios, acumulando 48 publicaciones (45.92%), lo que demuestra una dispersión internacional considerable, aunque con una clara concentración en economías con alta inversión en I+D+i. Esta distribución confirma que la IAG aplicada a ingeniería presenta una dinámica investigativa global, aunque con liderazgo marcado de naciones tecnológicamente avanzadas.




Fig. 3 Gráfico global de países

B) Resultados académicos

RQ1: ¿Cuáles son las problemáticas específicas abordadas mediante la aplicación de IAG en las distintas especialidades de la ingeniería?

El análisis sistemático de la literatura indica que la aplicación predominante de la Inteligencia Artificial

Generativa se concentra en la optimización de procesos industriales y químicos, donde los modelos generativos y metaheurísticos contribuyen a maximizar el rendimiento operativo, mejorar la eficiencia energética y reducir costos asociados a líneas de producción y plantas de procesamiento [1], [2], [3]. En el ámbito del diseño generativo y la simulación avanzada, la IAG facilita la creación automatizada de múltiples configuraciones técnicas y su integración con modelos físicos o digitales, ampliando significativamente el espacio de búsqueda de soluciones en ingeniería mecánica, electrónica y ciencia de materiales [25], [26], [27]. En mantenimiento predictivo, los enfoques generativos permiten sintetizar datos y reconstruir señales complejas, fortaleciendo la detección temprana de anomalías y aumentando la confiabilidad de sistemas industriales críticos [28], [29], [30]. En el sector de telecomunicaciones, la IAG se integra en la gestión inteligente de infraestructuras 5G/6G y arquitecturas SDN, optimizando la asignación dinámica de recursos y reduciendo latencias en entornos de alta demanda [31]. Finalmente, en el campo de la sostenibilidad y la energía, los modelos generativos se emplean para simular emisiones, diseñar procesos químicos más limpios y formular estrategias de eficiencia energética alineadas con objetivos de descarbonización industrial [34]. En conjunto, estos hallazgos evidencian que la IAG se posiciona como una herramienta transversal capaz de intervenir en problemas de alta complejidad estructural, particularmente en dominios donde la optimización multiobjetivo y la modelación avanzada resultan determinantes.

TABLA IV
ÁREAS ABORDADAS

Categoría	Cantidad de estudios	Porcentaje	Estudios que lo reportan
Optimización de procesos industriales y químicos	77	59.7	[1, 2, 3, 4, 7, 8, 9, 10, 11, 12, 13,...62]
Otras aplicaciones	35	27.1	[33, 54, 55, 31, 32, 33, 34,... 72]
Diseño generativo y simulación	25	19.4	[19, 20, 21, 24, 25, 28, 61]
Mantenimiento predictivo y calidad	8	6.2	[6, 27, 42, 43, 49, 34, 48, 59]
Telecomunicaciones y redes (5G/6G/SDN)	7	5.4	[5, 36, 18, 40, 43, 52, 53]
Sostenibilidad y energía	4	3.1	[34, 37, 39, 41]
Software e ingeniería de software	2	1.6	[11, 39]
Documentación técnica/LLM en ingeniería	1	0.8	[23]
Educación en ingeniería / formación	1	0.8	[20]
Logística y cadena de suministro	1	0.8	[10]

RQ2:¿Qué arquitecturas, modelos y técnicas de IAG se implementan para enfrentar desafíos relacionados con automatización, optimización o diseño en entornos ingenieriles?

La evidencia revisada indica que la aplicación de la IAG en automatización y diseño ingenieril se fundamenta predominantemente en arquitecturas de aprendizaje profundo, destacando modelos como CNN, RNN y DNN, empleados para extracción automática de características, procesamiento de señales y generación de soluciones en entornos industriales complejos [9], [15], [31]. De forma complementaria, el Machine Learning tradicional mantiene una presencia significativa mediante técnicas como SVM, KNN, Random Forest y modelos de ensamble, los cuales permiten clasificar estados operativos, identificar variables relevantes y proponer configuraciones de diseño con eficiencia computacional optimizada [1], [3], [37]. Asimismo, numerosos estudios incorporan optimizadores heurísticos, particularmente PSO, Differential Evolution y algoritmos genéticos, adecuados para la exploración de espacios de búsqueda extensos y la resolución de problemas multiobjetivo bajo restricciones industriales [2], [7], [8]. Finalmente, se identifican enfoques adicionales de naturaleza heterogénea, agrupados en la categoría “Otros”, que integran métodos híbridos o emergentes de difícil clasificación taxonómica.




Fig. 4 Técnicas y modelos de inteligencia artificial generativa

RQ3:¿Cómo se desempeñan las soluciones fundamentadas en IAG frente a métodos tradicionales o enfoques de inteligencia artificial no generativa en términos de precisión, eficacia y rendimiento operativo?

Los métodos tradicionales y los enfoques de inteligencia artificial no generativa presentan un desempeño variable según el contexto de aplicación. Una proporción relevante de estudios no establece comparaciones experimentales directas ni ofrece conclusiones concluyentes sobre la superioridad relativa de los modelos evaluados [4], [7], [38], [39]. En los trabajos que sí incorporan análisis comparativos, las arquitecturas de Deep Learning evidencian mayores niveles de precisión y capacidad predictiva, particularmente en

escenarios de clasificación y procesamiento de señales de alta complejidad [23], [40], [41], [42], [43]. Paralelamente, técnicas de Machine Learning tradicional, como SVM y Random Forest, conservan ventajas competitivas en contextos donde la estructura y dimensionalidad de los datos favorecen modelos menos profundos, ofreciendo resultados robustos con menor demanda computacional [44], [45], [46], [47]. Finalmente, un subconjunto más acotado de investigaciones reporta que técnicas basadas en IAG, especialmente aquellas que incorporan generación o ampliación sintética de datos, superan enfoques convencionales en términos de estabilidad y precisión en dominios específicos [30], [48], [49], [50], [51].

TABLA V
MÉTODOS TRADICIONALES Y OTROS MODELOS DE IAG

categoria	Cantidad de estudios	Porcentaje	Estudios que lo reportan
No compara / No concluye	51	39.5	[4, 11, 13, 15, 44, 78, ..., 92]
Otros	51	39.5	[2, 3, 6, 12, 24, 25, ...82]
Deep Learning superior	22	17.1	[1, 14, 16, 18, 22, ..., 96]
ML tradicional superior	19	14.7	[10, 17, 39, 40, ... 91]
IAG superior	15	11.6	[5, 7, 30, 37, ..., 98]

RQ4:¿Qué evidencias empíricas reportan mejoras en productividad, eficiencia y confiabilidad tras la incorporación de IAG en la solución de problemas de ingeniería?

La evidencia analizada indica que la implementación de IAG produce impactos positivos en múltiples indicadores de desempeño en ingeniería. Las mejoras en eficiencia constituyen el resultado más frecuente, reflejadas en reducción de tiempos de procesamiento, optimización energética y uso más eficiente de recursos en entornos industriales [13], [32], [52], [53], [54]. Asimismo, se observa un aumento en la productividad, particularmente en manufactura y sistemas automatizados, donde la IAG acorta ciclos operativos, incrementa el throughput y fortalece la toma de decisiones en tiempo real [3], [10], [55], [56]. En términos de confiabilidad, los modelos generativos facilitan la detección anticipada de fallas, mejoran la robustez de los sistemas y disminuyen tasas de error en procesos críticos [20], [36], [40], [51], [57], [58]. No obstante, una proporción significativa de estudios no presenta métricas cuantitativas explícitas, evidenciando heterogeneidad en el rigor y la calidad del reporte experimental [59], [60], [61], [62], [63].




Fig. 5 Aplicación de la IAG

RQ5: ¿Cuáles son los mecanismos de validación utilizados para evaluar soluciones basadas en IAG en contextos industriales y qué limitaciones, riesgos o restricciones metodológicas se identifican en su implementación?

La evidencia revisada indica que las soluciones sustentadas en IAG se evalúan predominantemente mediante técnicas de validación cruzada estadística, orientadas a estimar de forma reproducible la precisión, estabilidad y capacidad predictiva de los modelos [16], [22], [53], [64], [65]. Asimismo, una proporción relevante de trabajos implementa de manera complementaria, un número significativo de investigaciones incorpora validaciones en entornos industriales reales, empleando datos operativos, líneas de producción activas o pilotos experimentales para comprobar aplicabilidad práctica y robustez funcional [23], [66], [67], [68]. La contrastación frente a baselines convencionales constituye otra práctica frecuente, permitiendo cuantificar mejoras respecto a métodos no generativos o enfoques analíticos tradicionales [17], [24], [33], [69], [70]. En relación con las restricciones identificadas, sobresalen la limitada disponibilidad de datos, la elevada demanda computacional, dificultades de generalización y riesgos de sobreajuste en escenarios caracterizados por alta variabilidad o ruido industrial [38], [71], [72], [73], [74]. Estos hallazgos subrayan la necesidad de establecer marcos de validación más estandarizados y consistentes que respalden implementaciones confiables a escala productiva.




Fig. 6 Soluciones y limitaciones de la IAG

IV. DISCUSIÓN Y CONCLUSIONES

La síntesis de los 98 estudios (2023–2026) confirma que la Inteligencia Artificial Generativa está redefiniendo múltiples dominios de la ingeniería mediante optimización avanzada, simulación compleja y automatización inteligente. El crecimiento sostenido del periodo analizado evidencia consolidación científica del campo. Sus contribuciones se reflejan en reducción de costos, mejora de eficiencia y aumento de robustez operativa en manufactura, energía y telecomunicaciones [1], [8], [9], [75]. Ejemplos incluyen optimización energética en manufactura [76], [77], modelado químico avanzado [78], e integración con IoT y redes 5G/6G [79], [80]. No obstante, persisten desafíos estructurales vinculados a la calidad de datos, costos computacionales y validación industrial limitada.

La evidencia muestra que el 59.7% de los estudios se concentra en optimización industrial y química, consolidando este dominio como eje central de aplicación. Se reportan avances en manufactura aditiva [73], control energético [81], diagnóstico de fallas [39], y simulación de semiconductores [82]. En telecomunicaciones, modelos generativos optimizan redes y detección de fraudes [32], [79] mientras áreas emergentes como sostenibilidad [84], software [35], y educación [77] presentan menor representación, aunque alto potencial de expansión.

El examen de la literatura evidencia que los optimizadores heurísticos incluyendo algoritmos genéticos, PSO, Differential Evolution y enfoques híbridos predominan con una presencia del 90.7%, debido a su solidez frente a problemas no lineales y su eficacia en la exploración de espacios de búsqueda extensos bajo restricciones industriales complejas [1], [19], [85], [86]. La categoría “otros” (76.7%) agrupa modelos generativos como GANs aplicadas a manufactura aditiva [61], enfoques generativos en ingeniería química [15], LLMs orientados a documentación técnica [87], y aprendizaje por refuerzo avanzado para optimización productiva [88]. El Deep Learning (34.1%) destaca mediante CNNs para inspección visual en PCBs [89], [54], redes recurrentes en predicción de mantenimiento [33], y arquitecturas híbridas para simulación eléctrica [84]. Por su parte, el Machine Learning tradicional (27.9%) conserva relevancia en clasificación operativa y selección de variables críticas [37], [90], [91]. Investigaciones recientes integran IAG con sistemas IoT y arquitecturas ciberfísicas mediante modelos multimodales [92], impulsando automatización avanzada en entornos 4.0 y 5.0. En conjunto, la evidencia sugiere una transición hacia enfoques híbridos, donde la IAG complementa más que sustituye técnicas convencionales para mejorar precisión, eficiencia y adaptabilidad en escenarios dinámicos o estructuralmente inciertos.

Los estudios analizados evidencian una notable heterogeneidad en los esquemas comparativos: el 39.5% no realiza contrastes directos ni ofrece conclusiones concluyentes, lo que representa una limitación metodológica relevante. Entre los trabajos que sí incorporan comparación, las arquitecturas de Deep Learning muestran superioridad en el 17.1% de los casos,

especialmente en clasificación visual, análisis acústico y detección de anomalías, como reportan Hoffmann & Reich [40] en manufactura y Jin et al. [38] en tratamiento de agua. El Machine Learning tradicional supera métodos más complejos en el 14.7%, particularmente cuando los datos son limitados o se requiere interpretabilidad, como en optimización industrial y predicción energética [17], [93]. Por su parte, la IAG aventaja enfoques convencionales en el 11.6%, destacando en generación sintética de datos [48], simulación de procesos complejos [50], y control autónomo [11]. No obstante, su desempeño depende del dominio, la calidad de datos y la arquitectura empleada; problemas de sobreajuste y limitada generalización han sido documentados [13]. En consecuencia, la evidencia sugiere que la IAG actúa como complemento estratégico más que como sustituto absoluto de modelos tradicionales.

Las mejoras más frecuentemente reportadas se vinculan con la eficiencia operativa (54.3%), reflejada en reducción de tiempos de procesamiento, optimización energética, uso más eficiente de maquinaria y disminución de pérdidas en producción. Estos hallazgos se alinean con investigaciones que evidencian aceleración de ciclos de manufactura [19], fortalecimiento del mantenimiento predictivo [94] y mitigación de fallas en sistemas industriales de alto costo [55]. La productividad (24%) muestra incrementos significativos en sectores donde la decisión en tiempo real es determinante, como manufactura inteligente [30], sistemas eléctricos [20] y procesos químicos [49]. Asimismo, el 14% de los estudios reporta mejoras en confiabilidad, particularmente en infraestructuras críticas como turbinas [56], motores eléctricos [74], inspección óptica automatizada [95], y control térmico [96]. Sin embargo, el 50.4% no presenta métricas cuantitativas explícitas, lo que evidencia la necesidad de estandarizar indicadores de desempeño. En conjunto, aunque la IAG demuestra impactos sustanciales en diversas dimensiones del rendimiento ingenieril, su magnitud varía según diseño experimental, calidad de datos y complejidad arquitectónica.

La estrategia de validación predominante corresponde a la validación cruzada estadística, empleada en el 91.5% de los estudios, lo que refleja una orientación académica centrada en garantizar precisión, estabilidad y reproducibilidad de los modelos. No obstante, únicamente el 59.7% incorpora pruebas en entornos industriales reales o pilotos controlados, lo que sugiere que las soluciones basadas en IAG aún presentan un nivel de madurez limitado para su adopción masiva. Entre las aplicaciones validadas en contextos reales se incluyen optimización de redes IoT [45], diagnóstico de fallas en motores industriales [92], control de convertidores resonantes [97], y monitoreo energético avanzado [35]. El 41.9% de los trabajos realiza comparaciones con baselines tradicionales, fortaleciendo el rigor experimental, aunque sin alcanzar evidencia concluyente universal. En cuanto a restricciones, destacan la escasez de datos (23.3%), elevados costos computacionales (14%), dificultades de generalización (5.4%) y presencia de sobreajuste (1.6%). Investigaciones como las de Di Bonito et al. [97] y Zhao et al. [73] subrayan que la limitada diversidad de datos industriales restringe la extrapolación de

modelos generativos, mientras que estudios en IA explicable [23], [65], [98] enfatizan la necesidad de mayor transparencia y trazabilidad en aplicaciones críticas. En síntesis, aunque los esquemas de validación muestran avances, la implementación industrial continúa condicionada por desafíos estructurales vinculados a infraestructura, seguridad, escalabilidad y gobernanza ética.

CONCLUSIONES

La evidencia cuantitativa confirma que la IAG se concentra principalmente en optimización industrial (59.7%) y diseño–simulación (19.4%), mientras mantenimiento predictivo (6.2%) y telecomunicaciones (5.4%) muestran adopción intermedia. Sostenibilidad (3.1%) y educación (0.8%) permanecen incipientes, revelando desequilibrios temáticos y oportunidades de expansión en dominios subexplorados.

Metodológicamente, predominan optimizadores heurísticos (90.7%) y modelos generativos avanzados (76.7%), seguidos de Deep Learning (34.1%) y Machine Learning tradicional (27.9%). No obstante, el 39.5% carece de comparaciones experimentales claras; cuando existen, Deep Learning supera técnicas tradicionales en 17.1%, ML en 14.7% e IAG en 11.6%.

En desempeño ingenieril, el 54.3% reporta mejoras en eficiencia, 24% en productividad y 14% en confiabilidad, aunque el 50.4% no presenta métricas cuantificables robustas. La validación se basa en cross-validation (91.5%) y pruebas reales (59.7%), pese a limitaciones en datos (23.3%) y costos computacionales (14%).

REFERENCES

- [1] E. Altay, O. Altay, y Y. Özçevik, «A Comparative Study of Metaheuristic Optimization Algorithms for Solving Real-World Engineering Design Problems», *Comput. Model. Eng. Sci.*, vol. 139, n.º 1, pp. 1039-1094, 2023, doi: 10.32604/cmescs.2023.029404.
- [2] D. G. S. Pivoto, F. A. P. de Figueiredo, C. Cavdar, G. R. de L. Tejerina, y L. L. Mendes, «A Comprehensive Survey of Machine Learning Applied to Resource Allocation in Wireless Communications», *IEEE Commun. Surv. Tutor.*, pp. 1-1, 2025, doi: 10.1109/COMST.2025.3552370.
- [3] P. Miralles, K. Thangavel, Fulvio, Antonio, Jagadam, Nitya, Baranwal, Perna, y Faldu, Bhavin, «A critical review on the state-of-the-art and future prospects of machine learning for Earth observation operations», *Adv. Space Res.*, vol. 71, n.º 12, pp. 4959-4986, jun. 2023, doi: 10.1016/j.asr.2023.02.025.
- [4] Z. Hong, C. Z. Yong, K. Lucky, G. J. Rong, y W. Joheng, «A Data-Driven Approach for Improving Energy Efficiency in a Semiconductor Manufacturing Plant», *IEEE Trans. Semicond. Manuf.*, vol. 37, n.º 4, pp. 475-480, nov. 2024, doi: 10.1109/TSM.2024.3483781.
- [5] P. Zhou, A. Ghabeli, M. Ainslie, y F. Grilli, «Characterization of flux pump-charging of high-temperature superconducting coils using coupled numerical models», *Supercond. Sci. Technol.*, vol. 36, n.º 11, 2023, doi: 10.1088/1361-6668/acf739.
- [6] F. Phillipson, «Quantum Computing in Telecommunication—A Survey», *Mathematics*, vol. 11, n.º 15, p. 3423, ene. 2023, doi: 10.3390/math11153423.
- [7] A. Mozo, A. Karamchandani, L. de la Cal, S. Gómez-Canaval, A. Pastor, y L. Gifre, «A Machine-Learning-Based Cyberattack Detector for a Cloud-Based SDN Controller», *Appl. Sci.*, vol. 13, n.º 8, p. 4914, ene. 2023, doi: 10.3390/app13084914.
- [8] M.-F. R. Lee, «A Review on Intelligent Control Theory and Applications in Process Optimization and Smart Manufacturing», *Processes*, vol. 11, n.º 11, p. 3171, nov. 2023, doi: 10.3390/pr11113171.

- [9] S. J. Plathottam, A. Rzonca, R. Lakhnori, y C. O. Iloeje, «A review of artificial intelligence applications in manufacturing operations», *J. Adv. Manuf. Process.*, vol. 5, n.º 3, p. e10159, 2023, doi: 10.1002/amp.2.10159.
- [10] J. A. Gomez Camperos, M. M. Hernández Cely, y A. Pardo García, «Artificial Intelligence Techniques for the Hydrodynamic Characterization of Two-Phase Liquid-Gas Flows: An Overview and Bibliometric Analysis», *Fluids*, vol. 9, n.º 7, p. 158, jul. 2024, doi: 10.3390/fluids9070158.
- [11] S. Tiwari, «Artificial Intelligence (AI) in the Sustainable Energy Sector», *Eng. Proc.*, vol. 37, n.º 1, p. 11, 2023, doi: 10.3390/ECP2023-14609.
- [12] S. Badini, S. Regondi, E. Frontoni, y R. Pugliese, «Assessing the capabilities of ChatGPT to improve additive manufacturing troubleshooting», *Adv. Ind. Eng. Polym. Res.*, vol. 6, n.º 3, pp. 278-287, jul. 2023, doi: 10.1016/j.aiepr.2023.03.003.
- [13] I. Podder, T. Fischl, y U. Bub, «Artificial Intelligence Applications for MEMS-Based Sensors and Manufacturing Process Optimization», *Telecom*, vol. 4, n.º 1, pp. 165-197, mar. 2023, doi: 10.3390/telecom4010011.
- [14] N. Alhajeri, M. Nasr, y A. Osman, «Artificial intelligence-enabled optimization of Fe/Zn@biochar photocatalyst for 2,6-dichlorophenol removal from petrochemical wastewater: A techno-economic perspective», *Chemosphere*, vol. 352, p. 141476, mar. 2024, doi: 10.1016/j.chemosphere.2024.141476.
- [15] S.-S. Park y R.-Y. Kim, «A Novel Hybrid Analysis Method of LLC Resonant Converter for High Accuracy and Low Computational Burden», *IEEE Access*, vol. 13, pp. 137086-137101, 2025, doi: 10.1109/ACCESS.2025.3593996.
- [16] A. Matta, L. Matos, J. Silva, M. Gomes, A. Pilastrí, y P. Cortez, «A predictive analytics framework for early detection of production halts and quality issues», *Decis. Anal. J.*, vol. 16, p. 100607, sep. 2025, doi: 10.1016/j.dajour.2025.100607.
- [17] J. E. Naranjo, M. M. Llumiquinga, W. D. Vaca, y C. X. Espin, «Generative AI vs. Traditional Databases: Insights from Industrial Engineering Applications», *Publications*, vol. 13, n.º 2, p. 14, jun. 2025, doi: 10.3390/publications13020014.
- [18] A. Arias, G. Feijoo, y M. Moreira, «How could Artificial Intelligence be used to increase the potential of biorefineries in the near future? A review», *Environ. Technol. Innov.*, vol. 32, p. 103277, nov. 2023, doi: 10.1016/j.eti.2023.103277.
- [19] D. Y. A. Santillan, L. A. N. Sandoval, A. I. M. Santillán, P. J. A. Yataco, H. S. P. Quispe, y N. R. H. Huapaya, «Industrial process optimization through advanced HMI systems: exploring the integration of IoT and AI», *Indones. J. Electr. Eng. Comput. Sci.*, vol. 36, n.º 2, pp. 817-825, nov. 2024, doi: 10.11591/ijeecs.v36.i2.pp817-825.
- [20] C. Seo, D. Yoo, y Y. Lee, «Empowering Sustainable Industrial and Service Systems through AI-Enhanced Cloud Resource Optimization», *Sustainability*, vol. 16, n.º 12, p. 5095, ene. 2024, doi: 10.3390/su16125095.
- [21] M. Jamali, N. Hajialigol, y A. Fattahi, «An insight into the application and progress of artificial intelligence in the hydrogen production industry: A review», *Mater. Today Sustain.*, vol. 30, p. 101098, jun. 2025, doi: 10.1016/j.mtsust.2025.101098.
- [22] A. Bisconti, E. Popovici, y A. Temko, «Machine Learning for FPGA Electronic Design Automation», *IEEE Access*, vol. 12, pp. 182640-182662, 2024, doi: 10.1109/ACCESS.2024.3511345.
- [23] J. Hu y G. Jin, «An Intelligent Framework for English Teaching through Deep Learning and Reinforcement Learning with Interactive Mobile Technology», *Int. J. Interact. Mob. Technol. IJIM*, vol. 18, n.º 09, pp. 74-87, may 2024, doi: 10.3991/ijim.v18i09.49289.
- [24] S. Malik y A. Rana, «The Impact of Artificial Intelligence on Organizational Efficiency and Innovation», *J. Graph. Era Univ.*, pp. 183-204, mar. 2025, doi: 10.13052/jgeu0975-1416.1319.
- [25] J. Wanyama, E. Bwambale, S. Kiraga, y A. Katimbo, «A systematic review of fourth industrial revolution technologies in smart irrigation: Constraints, opportunities, and future prospects for sub-Saharan Africa», *Smart Agric. Technol.*, vol. 7, p. 100412, mar. 2024, doi: 10.1016/j.atech.2024.100412.
- [26] P. Piankitrunreang, K. Chaiprabha, W. Chungsangsatiporn, C. Ratanasumawong, P. Chancharoen, y R. Chancharoen, «Acoustic-Based Machine Main State Monitoring for High-Speed CNC Drillings», *Machines*, vol. 13, n.º 5, p. 372, may 2025, doi: 10.3390/machines13050372.
- [27] J. Nuerk y F. Daëna, «Activating supply chain business models' value potentials through Systems Engineering», *Syst. Eng.*, vol. 26, n.º 5, pp. 660-674, 2023, doi: 10.1002/sys.21676.
- [28] Y. Wang y T. Zhao, «A High-Efficiency Low-Wearing Hybrid Voltage Regulator for Utility Applications», *IEEE Open J. Ind. Appl.*, vol. 4, pp. 60-74, 2023, doi: 10.1109/OJIA.2023.3237732.
- [29] M. N. Dehaghani, T. Korötko, y A. Rosin, «AI Applications for Power Quality Issues in Distribution Systems: A Systematic Review», *IEEE Access*, vol. 13, pp. 18346-18365, 2025, doi: 10.1109/ACCESS.2025.3533702.
- [30] Y. Shan et al., «AI-driven generative and reinforcement learning for mechanical optimization of 2D patterned hollow structures», *Mater. Futur.*, vol. 4, n.º 3, p. 035001, jul. 2025, doi: 10.1088/2752-5724/ade732.
- [31] S. Wang, H. Cao, y L. Yang, «A hierarchical reinforcement learning approach for energy-aware service function chain dynamic deployment in IoT», *IET Commun.*, vol. 18, n.º 18, pp. 1231-1243, 2024, doi: 10.1049/cmu2.12824.
- [32] W. Deng, G. Liang, C. Yu, K. Yao, C. Wang, y X. Zhang, «An Early Warning Model of Telecommunication Network Fraud Based on User Portrait», *Comput. Mater. Contin.*, vol. 75, n.º 1, pp. 1561-1576, 2023, doi: 10.32604/cmc.2023.035016.
- [33] H. Meng, L. Ma, L. Su, B. Lu, D. Hou, y X. Du, «Inheritance of Intangible Culture Based on Wireless Communication Network in College Dance Teaching», *Int. J. Web-Based Learn. Teach. Technol. IJWLTT*, vol. 19, n.º 1, pp. 1-19, 2024, doi: 10.4018/IJWLTT.340936.
- [34] M. Madanchian y H. Taherdoost, «AI-Powered Innovations in High-Tech Research and Development: From Theory to Practice», *Comput. Mater. Contin.*, vol. 81, n.º 2, pp. 2133-2159, 2024, doi: 10.32604/cmc.2024.057094.
- [35] M. Liu, J. Wang, T. Lin, Q. Ma, Z. Fang, y Y. Wu, «An Empirical Study of the Code Generation of Safety-Critical Software Using LLMs», *Appl. Sci.*, vol. 14, n.º 3, p. 1046, ene. 2024, doi: 10.3390/app14031046.
- [36] L. Shao et al., «Artificial intelligence-driven distributed acoustic sensing technology and engineering application», *PhotonIX*, vol. 6, n.º 1, p. 4, feb. 2025, doi: 10.1186/s43074-025-00160-z.
- [37] A. Bindle, P. Singla, S. Sharma, A. Khakimov, R. I. Alkanhel, y A. Muthanna, «A Hybrid Large Language Model for Context-Aware Document Ranking in Telecommunication Data», *IEEE Access*, vol. 13, pp. 120345-120359, 2025, doi: 10.1109/ACCESS.2025.3585637.
- [38] L. Jin, H. Huang, y H. Ren, «AI-driven transformation of water treatment technology and industry: toward a new era of comprehensive innovation», *Front. Environ. Sci. Eng.*, vol. 19, n.º 8, p. 114, may 2025, doi: 10.1007/s11783-025-2034-3.
- [39] T. Yu, J. Tang, Q. Yu, L. Li, Y. Liu, y R. Poler, «Large language models for PHM: a review of optimization techniques and applications», *Auton. Intell. Syst.*, vol. 5, n.º 1, p. 18, ago. 2025, doi: 10.1007/s43684-025-00100-5.
- [40] R. Hoffmann y C. Reich, «A Systematic Literature Review on Artificial Intelligence and Explainable Artificial Intelligence for Visual Quality Assurance in Manufacturing», *Electronics*, vol. 12, n.º 22, p. 4572, ene. 2023, doi: 10.3390/electronics12224572.
- [41] J. Nieves, D. García, J. Angulo-Pines, F. Santos, y P. P. Rodríguez, «An Artificial Intelligence-Based Digital Twin Approach for Rejection Rate and Mechanical Property Improvement in an Investment Casting Plan», *Appl. Sci.*, vol. 15, n.º 4, p. 2013, ene. 2025, doi: 10.3390/app15042013.
- [42] F. Taktak, «AI-Enhanced Geomatics Engineering: Innovative Solutions and Applications Using ChatGPT, an Advanced AI Language Model», *Int. J. Eng. Geosci.*, vol. 10, n.º 1, pp. 36-45, feb. 2025, doi: 10.26833/ijeg.1510209.
- [43] D. Bratić, P. Miljković, D. Jurečić, y T. Grabarić, «AI-Driven Random Forest Model and the Six Sigma Approach for Enhancing Offset Printing Process and Product Quality», *Appl. Sci.*, vol. 15, n.º 5, p. 2266, ene. 2025, doi: 10.3390/app15052266.
- [44] P. Mannadhan, J. R. Szymański, M. Zurek-Mortka, y M. Sathiyarayanan, «A Novel Framework for the Iraqi Manufacturing Industry Towards the Adoption of Industry 4.0», *Sustainability*, vol. 16, n.º 20, p. 9045, ene. 2024, doi: 10.3390/su16209045.
- [45] Y. Hao, «Applying mechatronics-based internet of things in artificial intelligence image detection», *Int. J. Mechatron. Appl. Mech.*, vol. I, n.º 14, nov. 2023, doi: 10.17683/ijomam/issue14.17.
- [46] W. Villegas-Ch, R. Gutierrez, y J. Govea, «Digital twin integration in metalworking: enhancing efficiency and predictive maintenance», *Front. Mech. Eng.*, vol. 11, ago. 2025, doi: 10.3389/fmech.2025.1655565.
- [47] W. Villegas-Ch, J. García-Ortiz, y S. Sánchez-Viteri, «Toward Intelligent Monitoring in IoT: AI Applications for Real-Time Analysis and Prediction», *IEEE Access*, vol. 12, pp. 40368-40386, 2024, doi: 10.1109/ACCESS.2024.3376707.
- [48] T. Batu, H. G. Lemu, y H. Shimels, «Application of Artificial Intelligence for Surface Roughness Prediction of Additively Manufactured Components», *Materials*, vol. 16, n.º 18, p. 6266, ene. 2023, doi: 10.3390/ma16186266.
- [49] A. Ghandoura, A. Alajmi, M. El-Sakhawy, A. Motwakel, F. Dahan, y G. Abdelhady, «Dynamic Machine Learning Framework for Secure, Ultra-Reliable, and Energy-Efficient Open RAN Systems», *IEEE Open J. Commun. Soc.*, vol. 6, pp. 7016-7036, 2025, doi: 10.1109/OJCOMS.2025.3601501.
- [50] V. Bělohav, T. Jirout, M. Malecký, y T. Herink, «Effective application of operator training simulator in experiential education», *Comput. Appl. Eng. Educ.*, vol. 32, n.º 4, p. e22743, 2024, doi: 10.1002/cae.22743.
- [51] W. Chen, S. Yang, Y. Yan, Y. Gao, J. Zhu, y Z. Dong, «Empowering nanophotonic applications via artificial intelligence: pathways, progress, and prospects», *Nanophotonics*, vol. 14, n.º 4, pp. 429-447, feb. 2025, doi: 10.1515/nanoph-2024-0723.
- [52] M. Soori, F. Ghaleh, R. Dastres, y B. Arezoo, «Additive Manufacturing Modification by Artificial Intelligence, Machine Learning, and Deep Learning: A Review», *Addit. Manuf. Front.*, vol. 4, n.º 2, p. 200198, jun. 2025, doi: 10.1016/j.amf.2025.200198.
- [53] T. Miller et al., «Advancements in Artificial Intelligence Circuits and Systems (AICAS)», *Electronics*, vol. 13, n.º 1, p. 102, ene. 2024, doi: 10.3390/electronics13010102.
- [54] M. Kor, I. Yitmen, y S. Alizadehsalehi, «An investigation for integration of deep learning and digital twins towards Construction 4.0», *Smart Sustain. Built*

- Environ.*, vol. 12, n.º 3, pp. 461-487, mar. 2022, doi: 10.1108/SASBE-08-2021-0148.
- [55] M. Khurram *et al.*, «Artificial Intelligence in Manufacturing Industry Worker Safety: A New Paradigm for Hazard Prevention and Mitigation», *Processes*, vol. 13, n.º 5, p. 1312, may 2025, doi: 10.3390/pr13051312.
- [56] R. Leung, A. J. Hill, y A. Melkumyan, «Automation and Artificial Intelligence Technology in Surface Mining: A Brief Introduction to Open-Pit Operations in the Pilbara [Survey]», *IEEE Robot. Autom. Mag.*, vol. 32, n.º 3, pp. 164-183, sep. 2025, doi: 10.1109/MRA.2023.3328457.
- [57] A. Bondin y J. P. Zammit, «Education 4.0 for Industry 4.0: A Mixed Reality Framework for Workforce Readiness in Manufacturing», *Multimodal Technol. Interact.*, vol. 9, n.º 5, p. 43, may 2025, doi: 10.3390/mti9050043.
- [58] A. Chidara, K. Cheng, y D. Gallea, «Engineering Innovations for Polyvinyl Chloride (PVC) Recycling: A Systematic Review of Advances, Challenges, and Future Directions in Circular Economy Integration», *Machines*, vol. 13, n.º 5, p. 362, may 2025, doi: 10.3390/machines13050362.
- [59] J. Cederbladh, R. Eramo, V. Muttillio, y P. E. Strandberg, «Experiences and challenges from developing cyber-physical systems in industry-academia collaboration», *Softw. Pract. Exp.*, vol. 54, n.º 6, pp. 1193-1212, 2024, doi: 10.1002/spe.3312.
- [60] J. Emmert, R. Mendez, H. Dastjerdi, C. Syben, y A. Maier, «The Artificial Neural Twin — Process optimization and continual learning in distributed process chains», *Neural Netw.*, vol. 180, p. 106647, dic. 2024, doi: 10.1016/j.neunet.2024.106647.
- [61] J. Ajayan, A. Kumar Panigrahy, S. Sen, M. Kumar, y S. Tayal, «Reliability Issues and Degradation Mechanisms of p-GaN Gated E-Mode AlGaN/GaN Power HEMTs: A Critical Review», *IEEE Access*, vol. 13, pp. 84541-84554, 2025, doi: 10.1109/ACCESS.2025.3569288.
- [62] M. Alhusban, M. Alhusban, y A. A. Alkhalwaldeh, «The Efficiency of Using Machine Learning Techniques in Fiber-Reinforced-Polymer Applications in Structural Engineering», *Sustainability*, vol. 16, n.º 1, p. 11, ene. 2024, doi: 10.3390/su16010011.
- [63] V. Balaska *et al.*, «Machine Vision in Human-Centric Manufacturing: A Review from the Perspective of the Frozen Dough Industry», *Electronics*, vol. 14, n.º 17, p. 3361, ene. 2025, doi: 10.3390/electronics14173361.
- [64] I. Barraj, H. Mestiri, y M. Masmoudi, «Overview of Memristor-Based Design for Analog Applications», *Micromachines*, vol. 15, n.º 4, p. 505, abr. 2024, doi: 10.3390/mi15040505.
- [65] P. Dini, L. Diana, A. Elhanashi, y S. Saponara, «Overview of AI-Models and Tools in Embedded IIoT Applications», *Electronics*, vol. 13, n.º 12, p. 2322, ene. 2024, doi: 10.3390/electronics13122322.
- [66] V. García, A. Valencia, F. López, y E. Zapata, «Integrating artificial intelligence and quantum computing: A systematic literature review of features and applications», *Int. J. Cogn. Comput. Eng.*, vol. 7, pp. 26-39, dic. 2026, doi: 10.1016/j.ijcce.2025.08.002.
- [67] D.-W. Kim *et al.*, «Framework for Network Topology Generation and Traffic Prediction Analytics for Cyber Exercises», *IEEE Access*, vol. 12, pp. 23869-23880, 2024, doi: 10.1109/ACCESS.2023.3344170.
- [68] E. L. Luna y M. Á. Vidal, «Review of the Properties of GaN, InN, and Their Alloys Obtained in Cubic Phase on MgO Substrates by Plasma-Enhanced Molecular Beam Epitaxy», *Crystals*, vol. 14, n.º 9, p. 801, sep. 2024, doi: 10.3390/cryst14090801.
- [69] B. Mortazavi, «Recent Advances in Machine Learning-Assisted Multiscale Design of Energy Materials», *Adv. Energy Mater.*, vol. 15, n.º 9, p. 2403876, 2025, doi: 10.1002/aenm.202403876.
- [70] S. Ohinok, I. Kulyniak, M. Kohut, I. Gerlach, y O. Voronko, «Impact of Digital Technologies on Economic and Marketing Innovation and Competitiveness within VLSI System Employment», *J. VLSI Circuits Syst.*, vol. 7, n.º 1, pp. 1-10, ene. 2025, doi: 10.31838/jvcs/07.01.01.
- [71] K. Bello y R. Maladzi, «Innovative and best practices in sustainable strategies for waste reduction in additive manufacturing», *Hybrid Adv.*, vol. 11, p. 100527, dic. 2025, doi: 10.1016/j.hybadv.2025.100527.
- [72] M. Jimenez-Martinez, S. G. Torres-Cedillo, J. Cortés-Pérez, y A. Reyes-Solis, «Modal finite element correlation for computer aided engineering education», *Eng. Rep.*, vol. 6, n.º 8, p. e12808, 2024, doi: 10.1002/eng2.12808.
- [73] Y. Zhao, «Optimization of Mechanical Manufacturing Processes Via Deep Reinforcement Learning-Based Scheduling Models», *Informatica*, vol. 49, n.º 14, mar. 2025, doi: 10.31449/inf.v49i14.7204.
- [74] Z. Wang *et al.*, «Improving Semiconductor Device Modeling for Electronic Design Automation by Machine Learning Techniques», *IEEE Trans. Electron Devices*, vol. 71, n.º 1, pp. 263-271, ene. 2024, doi: 10.1109/TED.2023.3307051.
- [75] S. Soltani, A. Amanloo, M. Shojafar, y R. Tafazolli, «Intelligent Control in 6G Open RAN: Security Risk or Opportunity?», *IEEE Open J. Commun. Soc.*, vol. 6, pp. 840-880, 2025, doi: 10.1109/OJCOMS.2025.3526215.
- [76] J. F. Strutz, I. Samardžić, y K. Šimunović, «Optimization potentials of laser powder bed fusion: A conceptual approach», *FME Trans.*, vol. 51, n.º 3, pp. 432-448, 2023, doi: 10.5937/fme2303432S.
- [77] S. Simeonov, F. Feradov, A. Marinov, y T. Abu-Alam, «Integration of AI Training in the Field of Higher Education in the Republic of Bulgaria: An Overview», *Educ. Sci.*, vol. 14, n.º 10, p. 1063, oct. 2024, doi: 10.3390/educsci14101063.
- [78] O. Ibhadode *et al.*, «Topology optimization for metal additive manufacturing: current trends, challenges, and future outlook», *Virtual Phys. Prototyp.*, vol. 18, n.º 1, p. e2181192, dic. 2023, doi: 10.1080/17452759.2023.2181192.
- [79] K. Trantzas *et al.*, «Intent-driven network automation through sustainable multimodal generative AI», *EURASIP J. Wirel. Commun. Netw.*, vol. 2025, n.º 1, p. 42, jun. 2025, doi: 10.1186/s13638-025-02472-x.
- [80] M. Vargas, R. Mosquera, G. Fuertes, M. Alfaro, y I. G. Perez Vergara, «Process Optimization in a Condiment SME through Improved Lean Six Sigma with a Surface Tension Neural Network», *Processes*, vol. 12, n.º 9, p. 2001, sep. 2024, doi: 10.3390/pr12092001.
- [81] J. Zhang y S. Yang, «Recommendations for the Model-Based Systems Engineering Modeling Process Based on the SysML Model and Domain Knowledge», *Appl. Sci.*, vol. 14, n.º 10, p. 4010, ene. 2024, doi: 10.3390/app14104010.
- [82] C.-T. Wu, S.-H. Li, y D. C. Yen, «Predicting Work-in-Process in Semiconductor Packaging Using Neural Networks: Technical Evaluation and Future Applications», *Electronics*, vol. 13, n.º 21, p. 4275, ene. 2024, doi: 10.3390/electronics13214275.
- [83] H. Mas Har, D. A. Prasetyo, A. F. Andikos, L. Andre, E. Syofiana, y M. Amin, «The Effectiveness of the Work Based Learning Higher Order Thinking Skills Employability (Wbl-Hotse) Model on Student Learning Outcomes for 3T Regional Vocational High Schools», *Data Metadata*, vol. 4, 2025, doi: 10.56294/dm2025651.
- [84] S. Sivasubramani y T. Prodromakis, «Reaching new frontiers in nanoelectronics through artificial intelligence», *Front. Nanotechnol.*, vol. 7, jun. 2025, doi: 10.3389/fnano.2025.1627210.
- [85] S. Schleifer, A. Lungu, B. Kruse, S. van Putten, S. Goetz, y S. Wartack, «Use case identification of natural language system requirements with graph-based clustering», *Des. Sci.*, vol. 11, p. e30, ene. 2025, doi: 10.1017/dsj.2025.10019.
- [86] M. Ryalat, E. Franco, H. Elmoaqet, N. Almtireen, y G. Al-Refai, «The Integration of Advanced Mechatronic Systems into Industry 4.0 for Smart Manufacturing», *Sustainability*, vol. 16, n.º 19, p. 8504, ene. 2024, doi: 10.3390/su16198504.
- [87] E. Resendiz-Ochoa, S. Calderon-Urbe, L. A. Morales-Hernandez, C. A. Perez-Ramirez, y I. A. Cruz-Albarran, «Multiple Electromechanical-Failure Detection in Induction Motor Using Thermographic Intensity Profile and Artificial Neural Network», *Machines*, vol. 12, n.º 12, p. 928, dic. 2024, doi: 10.3390/machines12120928.
- [88] N. V. D. S. S. V. P. Raju *et al.*, «LegalMind: Agentic AI-Driven Process Optimization and Cost Reduction in Legal Services Using DeepSeek», *IEEE Access*, vol. 13, pp. 126981-126999, 2025, doi: 10.1109/ACCESS.2025.3586781.
- [89] G. Na y H. Kimb, «Metaheuristics-guided active learning for optimizing reaction conditions of high-performance methane conversion», *Appl. Soft Comput.*, vol. 164, p. 111935, oct. 2024, doi: 10.1016/j.asoc.2024.111935.
- [90] Y.-Y. Hong y D. Josh Domingo Lopez, «A Review on Quantum Machine Learning in Applied Systems and Engineering», *IEEE Access*, vol. 13, pp. 144607-144631, 2025, doi: 10.1109/ACCESS.2025.3599147.
- [91] A. Redchuk, F. Walas Mateo, G. Pascal, y J. E. Tornillo, «Adoption Case of IIoT and Machine Learning to Improve Energy Consumption at a Process Manufacturing Firm, under Industry 5.0 Models», *Big Data Cogn. Comput.*, vol. 7, n.º 1, p. 42, mar. 2023, doi: 10.3390/bdcc7010042.
- [92] D.-E. A. Mansour *et al.*, «Applications of IIoT and digital twin in electrical power systems: A comprehensive survey», *IET Gener. Transm. Distrib.*, vol. 17, n.º 20, pp. 4457-4479, 2023, doi: 10.1049/gtd2.12940.
- [93] J. Wang, «Intelligent Education Based on Mobile Learning: Transitioning from Traditional Classrooms to Adaptive Learning Environments», *Int. J. Interact. Mob. Technol. LIIM*, vol. 19, n.º 11, pp. 51-65, jun. 2025, doi: 10.3991/ijim.v19i11.56057.
- [94] M. Khaled, M. Al-Dhaifallah, y O. Tahac, «Artificial intelligence perspectives: A systematic literature review on modeling, control, and optimization of fluid catalytic cracking», *Alex. Eng. J.*, vol. 80, pp. 294-314, oct. 2023, doi: 10.1016/j.aej.2023.08.066.
- [95] Q.-R. Lin, B.-C. Hu, L.-Y. Kuo, y T.-Y. Shen, «Development of Automatic Inspection and Optimization Platform for Computer Numerical Control Machining Using Automatic Optical Inspection and Artificial Intelligence», *Eng. Proc.*, vol. 92, n.º 1, p. 87, 2025, doi: 10.3390/engproc2025092087.
- [96] M. Bilal, S. Petrovich, y K. Ebrahimi, «Electric Vehicle Thermal System Concept Development for Multiple Variants Using Digital Prototype and AI», *Processes*, vol. 12, n.º 11, p. 2314, nov. 2024, doi: 10.3390/pr12112314.
- [97] L. P. Di Bonito, L. Campanile, F. Di Natale, M. Mastroianni, y M. Iacono, «eXplainable Artificial Intelligence in Process Engineering: Promises, Facts, and Current Limitations», *Appl. Syst. Innov.*, vol. 7, n.º 6, p. 121, dic. 2024, doi: 10.3390/asi7060121.
- [98] A. Diedrich, S. Windmann, y O. Niggemann, «Solving industrial fault diagnosis problems with quantum computers», *Quantum Mach. Intell.*, vol. 6, n.º 2, p. 66, oct. 2024, doi: 10.1007/s42484-024-00184-x.