

A systematic review of artificial intelligence applications in reducing the carbon footprint of computer systems

Alva Navas Dayli Esthers¹ ; Gabriel Carrasco Arturo Pablo²  Zarate Segura Guillermo

¹Universidad Tecnológica del Perú, Perú, U24233427@utp.edu.pe

²Universidad Tecnológica del Perú, Perú, U24236341@utp.edu.pe

Abstract– This research aimed to analyze, through a systematic literature review, the applications of Artificial Intelligence (AI) geared towards reducing the carbon footprint of computing systems. To this end, a methodology based on the PRISMA guidelines was applied, conducting searches in high-impact academic databases such as Scopus, considering articles published between 2021 and 2025 related to AI, sustainability, energy efficiency, green software, and data centers. After the identification, screening, and eligibility process, 31 articles were selected that met the inclusion criteria defined by the PICO model. The results showed that AI is applied in multiple areas with significant improvements in energy efficiency and emissions reduction. In data centers, it is used to optimize energy consumption and thermal management, resource allocation, and real-time electricity consumption. In sustainable software, optimization algorithms and machine learning models are applied to reduce computational demand. In sectors such as industry, agriculture, and logistics, predictive models and hybrid techniques show significant reductions in CO₂ emissions and improvements in operational efficiency. Likewise, the growing adoption of digital twins, deep learning, and approaches based on dynamic optimization was identified. Despite this progress, significant gaps remain, as most research focuses on isolated sectoral applications, and a consolidated analysis of AI's contribution to computational systems specifically aimed at reducing carbon footprints is still lacking. In conclusion, these findings support the need for new strategic guidelines that incorporate dispersed contributions, synthesize trends, and establish clear and concise guidelines for developing more efficient computational architectures, thus contributing to both the scientific community and global sustainability goals.

Keywords– Artificial intelligence, carbon footprint, energy optimization, sustainability, computer systems.

Una revisión sistemática sobre aplicaciones de la inteligencia artificial en la reducción de la huella de carbono en sistemas computacionales

Alva Navas Dayli Esthers¹ ; Gabriel Carrasco Arturo Pablo² Zarate Segura Guillermo

¹Universidad Tecnológica del Perú, Perú, U24233427@utp.edu.pe

²Universidad Tecnológica del Perú, Perú, U24236341@utp.edu.pe

Resumen– Esta investigación tuvo como objetivo analizar, mediante una revisión sistemática de la literatura, las aplicaciones de la Inteligencia Artificial (IA) orientadas a la reducción de la huella de carbono de los sistemas computacionales. Para ello, se aplicó una metodología basada en las directrices PRISMA, realizando búsquedas en bases de datos académicas de alto impacto como Scopus, considerando artículos publicados entre 2021 y 2025 relacionados con IA, sostenibilidad, eficiencia energética, software verde y centros de datos. Tras el proceso de identificación, cribado y elegibilidad, se seleccionaron 31 artículos que cumplieron con los criterios de inclusión definidos por el modelo PICO. Los resultados mostraron que la IA se aplica en múltiples áreas con mejoras significativas en la eficiencia energética y la reducción de emisiones. En los centros de datos, se utiliza para optimizar el consumo energético y la gestión térmica, la asignación de recursos y el consumo eléctrico en tiempo real. En el software sostenible, se aplican algoritmos de optimización y modelos de aprendizaje automático para reducir la demanda computacional. En sectores como la industria, la agricultura y la logística, los modelos predictivos y las técnicas híbridas muestran reducciones significativas en las emisiones de CO₂ y mejoras en la eficiencia operativa. Asimismo, se identificó una creciente adopción de gemelos digitales, aprendizaje profundo y enfoques basados en optimización dinámica. A pesar de estos avances, persisten brechas importantes, ya que la mayoría de las investigaciones se centran en aplicaciones sectoriales aisladas, y aún falta un análisis consolidado sobre la contribución de la IA a los sistemas computacionales específicamente orientados a reducir la huella de carbono. En conclusión, estos hallazgos respaldan la necesidad de nuevas directrices estratégicas que integren contribuciones dispersas, sintetizen tendencias y establezcan lineamientos claros y concisos para el desarrollo de arquitecturas computacionales más eficientes, contribuyendo así tanto a la comunidad científica como a los objetivos globales de sostenibilidad.

Palabras clave: Inteligencia artificial, huella de carbono, optimización energética, sostenibilidad, sistemas computacionales.

I. INTRODUCCIÓN

El cambio climático y el aumento acelerado de las tecnologías digitales han puesto en evidencia el alto impacto energético y ambiental de los sistemas computacionales, peculiarmente en los centros de datos e infraestructura de software. La literatura señala la transformación digital basada en IA, Big Data e IoT puede aportar significativamente a la sostenibilidad a través de la optimización de procesos y aminorar las emisiones [1]. Asimismo, el manejo de IA en sistemas eléctricos manifiesta muy buenos aportes en predicción, balance de cargas y eficiencia energética, a pesar de que aún existen limitaciones afiliadas a la transparencia y

al costo ambiental de los diseños de aprendizaje [2]. Este progreso nos confirma la medida de poder investigar como la IA se convierte en un pilar para el mundo tecnológico hacia una computación más verde y sostenible.

Pese a los avances documentados, los estudios sobre IA y sostenibilidad se muestran fragmentados en sectores específicos. En el caso de la logística, se demuestra que los algoritmos de optimización disminuyen el consumo energético en cadenas de frío [3], en tanto en la agricultura de precisión la IA se comporta mucho mejor en el uso de recursos naturales y disminuye el impacto ambiental [4]. En el campo tecnológico, se ha analizado opciones como los sistemas de enfriamiento radiativo pasivo, los que, combinados con IA, tienen un gran valor significativo en la reducción en el consumo energético en infraestructuras digitales [5]. Aunque, estos aportes se muestran de forma aislada ya que no existe una revisión sistemática fijada que se enfoque específicamente el rol de la IA en la reducción de la huella de carbono en estos sistemas.

Este tema se justifica por su relevancia innovadora, ya que integra dos áreas que se encuentran en un creciente interés sobre la inteligencia artificial y sostenibilidad ambiental. A pesar de que existen estudios que muestran que la IA puede optimizar procesos y mejorar la eficiencia en diferentes sectores [1], [2]. Sin embargo, no se han encontrado RSL recientes que sistematicen su impacto directo en la reducción de la huella de carbono en sistemas computacionales. Esta carencia nos evidencia un vacío de conocimiento que limita la posibilidad de establecer lineamientos transparentes para el desarrollo de software verde y arquitecturas digitales sostenibles. En consecuencia, esta investigación propone una Revisión Sistemática de Literatura que no solo simplifique los aportes dispersos, sino que también aporte a la comunidad científica y a la industria herramientas para avanzar hacia una infraestructura tecnológica más eficiente y alineada con los Objetivos de Desarrollo Sostenible. A partir de lo expuesto, surge la siguiente pregunta de investigación que orienta este estudio: ¿Cómo las aplicaciones de la inteligencia artificial en sistemas computacionales contribuyen a la reducción de la huella de carbono y a la optimización energética en comparación con métodos tradicionales de gestión y optimización?

El propósito de esta revisión sistemática es analizar de manera integral la evidencia científica disponible sobre las

aplicaciones de la inteligencia artificial en sistemas computacionales, con el fin de identificar cómo estas tecnologías contribuyen a la reducción de la huella de carbono y a la optimización energética, en comparación con métodos tradicionales de gestión y control. Asimismo, se busca clasificar los tipos de algoritmos utilizados, evaluar su efectividad en términos de eficiencia energética y sostenibilidad, y determinar las principales brechas y desafíos que orienten futuras líneas de investigación hacia el desarrollo de una computación ambientalmente responsable y energéticamente optimizada.

La presente revisión sistemática se estructura en cinco secciones principales. La sección I desarrolla la introducción, que incluye el contexto, la formulación del problema, la justificación, así como la pregunta y los objetivos del estudio. En la sección II, se describe la metodología, que detalla la estrategia de búsqueda, las bases de datos consultadas, los criterios de selección y la aplicación del diagrama PRISMA. La sección III presenta los resultados, mostrando el número de estudios identificados, las características de las investigaciones seleccionadas y los hallazgos relacionados con el uso de la inteligencia artificial en la reducción de emisiones y la optimización energética. En la sección IV, se desarrolla la discusión, donde se contrastan los resultados obtenidos con los hallazgos de estudios previos, se interpretan las tendencias emergentes y se identifican los vacíos encontrados en la literatura. Finalmente, la sección V expone las conclusiones, en el cual se destacan los principales aportes de la revisión, los desafíos tecnológicos y las posibles líneas de investigación futura orientadas hacia la sostenibilidad de los sistemas computacionales mediante la aplicación de la inteligencia artificial.

II. METODOLOGÍA

El presente estudio se desarrolló bajo el enfoque de una Revisión Sistemática de la Literatura (RSL), cuyo propósito es recopilar, evaluar y simplificar de manera rigurosa los estudios existentes sobre la aplicación de la inteligencia artificial en sistemas computacionales orientados a la reducción de la huella de carbono y la optimización energética [6], [7]. Este enfoque fue seleccionado por su capacidad para identificar patrones, comparar metodologías y detectar falta de información en un campo interdisciplinario donde convergen la ingeniería computacional, la sostenibilidad y la gestión energética. La revisión se elaboró siguiendo las recomendaciones del protocolo PRISMA 2020, que garantiza transparencia y replicabilidad en las revisiones científicas [8].

Para la formulación de la pregunta de investigación se desarrolló utilizando la estrategia PICO (Population, Intervention, Comparison, Outcome), con la finalidad de definir de manera estructurada los componentes centrales del estudio y guiar la construcción de las ecuaciones de búsqueda

[6]. La pregunta general que orientó para elaboración de la revisión sistemática fue:

¿Cómo las aplicaciones de la inteligencia artificial en sistemas computacionales contribuyen a la reducción de la huella de carbono y a la optimización energética en comparación con métodos tradicionales de gestión y optimización?

En este sentido, suscitaron las siguientes subpreguntas para la investigación:

- RQ1: ¿Qué tipos de aplicaciones de inteligencia artificial se están utilizando actualmente para reducir la huella de carbono en sistemas computacionales?
- RQ2: ¿Qué impacto tienen estas aplicaciones en la eficiencia energética y en la reducción de emisiones de carbono?
- RQ3: ¿Cómo se comparan los enfoques basados en IA con los métodos tradicionales de optimización en cuanto a efectividad y sostenibilidad?
- RQ4: ¿En qué contextos tecnológicos (centros de datos, cloud computing, software verde, hardware especializado) se han implementado con mayor éxito estas soluciones?
- RQ5: ¿Qué limitaciones y desafíos han sido identificados en la literatura sobre el uso de IA para reducir la huella de carbono en sistemas computacionales?

A partir de estas preguntas se definieron los componentes del modelo PICO, como se muestra en la Tabla I:

TABLE I
COMPONENTES PICO Y PALABRAS CLAVE

Componente (PICO)	Descripción de los componentes	Palabras clave en Inglés
P (Población)	Huella de carbono en sistemas computacionales	Carbon footprint, Carbon emissions, Greenhouse gas emissions, ICT emissions, Digital carbon footprint, Computational systems, Computing systems, Energy consumption in computing
I (Intervención)	Aplicación de técnicas de Inteligencia Artificial	Artificial Intelligence, AI, Machine Learning, Deep Learning, Optimization algorithms, Predictive models, Intelligent systems, AI-based solutions
C (Comparación)	Métodos tradicionales de optimización energética	Traditional methods, Conventional optimization, Energy management, Resource allocation, Non-AI techniques, Baseline methods
O (Resultados)	Reducción de la huella de carbono / eficiencia energética	Carbon reduction, Emission reduction, Energy efficiency, Sustainable computing, Low-carbon computing, Energy optimization, Net-zero computing, Carbon neutrality, Green computing

C (Contexto)	Sistemas computacionales	Data centers, Cloud computing, Edge computing, High-performance computing, Internet of Things (IoT), Semiconductor industry, ICT infrastructure, Sustainable technology, Green data centers
--------------	--------------------------	---

A partir de estos componentes, se seleccionaron las palabras clave y sinónimos combinados mediante los operadores booleanos (AND, OR), que permitieron construir la ecuación avanzada de búsqueda utilizada en Scopus [7]. Esta estrategia permitió garantizar la coherencia conceptual y la precisión temática del proceso de identificación de artículos relevantes. La búsqueda sistemática se llevó a cabo entre los meses de agosto y octubre de 2025, utilizando la base de datos académica Scopus, seleccionada por su alta cobertura en ingeniería, sostenibilidad y ciencias computacionales. El rango temporal definido fue de 2021 a 2025, con el propósito de incluir investigaciones recientes que reflejen los avances más actuales en el uso de la IA para la optimización energética y la sostenibilidad ambiental. Las ecuaciones de búsqueda se formularon combinando operadores booleanos con palabras clave derivadas de la pregunta PICO de la investigación:

- (TITLE-ABS-KEY ("Carbon footprint" OR "Carbon emissions" OR "Greenhouse gas emissions" OR "ICT emissions" OR "Digital carbon footprint" OR "Computational systems" OR "Computing systems" OR "Energy consumption in computing"))
- AND TITLE-ABS-KEY ("Artificial Intelligence" OR "AI" OR "Machine Learning" OR "Deep Learning" OR "Reinforcement Learning" OR "Optimization algorithms" OR "Predictive models" OR "Intelligent systems" OR "AI-based solutions")
- AND TITLE-ABS-KEY ("Traditional methods" OR "Conventional optimization" OR "Energy management" OR "Resource allocation" OR "Non-AI techniques" OR "Baseline methods")
- AND TITLE-ABS-KEY ("Carbon reduction" OR "Emission reduction" OR "Energy efficiency" OR "Sustainable computing" OR "Low-carbon computing" OR "Energy optimization" OR "Net-zero computing" OR "Carbon neutrality" OR "Green computing")
- AND PUBYEAR > 2020 AND PUBYEAR
- AND (LIMIT-TO (SUBJAREA,"ENGI") OR LIMIT-TO (SUBJAREA,"COMP") OR LIMIT-TO (SUBJAREA, "ENER"))
- AND (LIMIT-TO (DOCTYPE "ar") OR LIMIT-TO (DOCTYPE, "re"))
- AND (LIMIT-TO (PUBSTAGE, "final"))
- AND (LIMIT-TO (SRCTYPE, "j"))
- AND (LIMIT-TO (LANGUAGE, "English"))

- AND (LIMIT-TO (OA, "all"))

Se aplicaron filtros para restringir los resultados a artículos y revisiones, en idioma inglés, revisadas por pares y clasificadas en áreas de ingeniería, computación y energía, y se encuentren disponibles en texto completo. En la búsqueda inicial se identificaron 138 artículos, de los cuales no hubo eliminados por duplicidad, quedando 138 registros únicos. Tras la lectura de títulos y resúmenes, se descartaron los estudios no relacionados con el ámbito computacional o sin aplicación de IA, reteniéndose 45 artículos para evaluación completa.

Finalmente, se obtuvo 39 estudios que fueron incluidos en la síntesis cualitativa y cuantitativa por cumplir con los criterios de selección. De los estudios seleccionados, 37 estudios correspondieron a revistas Q1 y 2 de ellos a revistas Q2 de acuerdo con la clasificación SJR, indicando que los estudios considerados provienen principalmente de fuentes de alta calidad. Asimismo, del total de estudios seleccionados 36 son artículos y 3 RSL. Entre ellos, el estudio de H.W. et al., 2021 se identifica como el más relevante, tanto por su ubicación en una revista Q1 como por la solidez metodológica y el impacto de sus hallazgos. Los criterios se definieron con base en los componentes de la pregunta PICO y en la alineación con los objetivos de la revisión.

Criterios de inclusión :

- CI1: Aplicaciones de IA orientadas a la optimización energética, reducción de emisiones o sostenibilidad computacional.
- CI2: Investigaciones que apliquen técnicas de IA (Machine Learning, Deep Learning, Reinforcement Learning, Optimización evolutiva).
- CI3: Estudios que comparen IA con métodos tradicionales o muestren mejoras frente a prácticas convencionales.
- CI4: Estudios que presenten resultados cuantitativos o comparativos frente a métodos tradicionales.

Criterios de exclusión

- CE1: Trabajos en contextos no computacionales (agricultura, transporte, salud, etc.) sin vínculo con infraestructura digital.
- CE2: Estudios sin uso explícito de IA o basados en modelos deterministas clásicos.
- CE3: Trabajos que no incluyan comparación ni evidencia frente a enfoques tradicionales.
- CE4: Ensayos teóricos, revisiones narrativas o sin evidencia empírica.

Estos criterios garantizaron la relevancia científica, técnica y contextual de los artículos incluidos, asegurando que la evidencia recopilada respondiera directamente a la pregunta de investigación planteada.

El proceso de selección se desarrolló en cuatro fases consecutivas siguiendo el modelo PRISMA:

- **Identificación:** se localizaron 140 estudios en la base de datos Scopus.
- **Cribado:** No hubo eliminados por duplicidad, pero se identificaron 93 artículos no relacionados con el objeto de estudio tras revisión de título y resumen, en la fase de evaluación completa, se recuperaron 47 estudios para revisión a texto completo. De lo cual, 2 no fueron accedidas porque requería suscripción para disponer del archivo.
- **Elegibilidad:** se analizaron 45 artículos a texto completo, evaluando su calidad metodológica y su correspondencia con los criterios de inclusión. De estos 5 fueron excluidos por las siguientes razones:
Razón 1: Estudios sin relación con sistemas computacionales.
Razón 2: Investigaciones sin aplicación de IA.
Razón 3: Sin comparación con métodos tradicionales.
Razón 4: Estudios teóricos, revisiones narrativas o sin evidencia empírica.
- **Inclusión final:** se incorporaron 39 estudios en la revisión sistemática para el análisis cualitativo y cuantitativo de los cuales pertenecían a revistas Q1 y Q2.

El diagrama de flujo PRISMA (Figura 1) resume este procedimiento, mostrando de forma visual las fases de exclusión e inclusión aplicadas para la obtención final de los estudios incluidos.




Fig. 1 Diagrama de flujo PRISMA.

De cada estudio que fueron seleccionados se extrajeron variables y características clave con la finalidad de realizar un análisis comparativo. Los datos recopilados incluyeron:

- Título del Artículo, autor(es), año de publicación, título de revista y fuente de publicación.
- Tipo de sistema computacional analizado (centros de datos, cloud computing, smart grids, edge computing, HVAC systems).
- Técnica de inteligencia artificial empleada (ML, DL, RL, algoritmos híbridos, optimización metaheurística).
- Indicadores de desempeño energético (consumo de energía, emisiones de carbono, tiempo de ejecución, costo computacional).
- Comparación frente a métodos tradicionales o sin IA.
- Resultados cuantitativos o porcentuales de mejora (eficiencia, reducción de CO₂, ahorro energético).

La información se sistematizó en una matriz de análisis en Excel, donde se clasificaron los artículos por año, tipo de IA y dominio de aplicación. Posteriormente, los datos fueron codificados temáticamente para identificar tendencias, patrones, desafíos y carencias de información.

III. RESULTADOS

RQ1: ¿Qué tipos de aplicaciones de inteligencia artificial se están utilizando actualmente para reducir la huella de carbono en sistemas computacionales?

Los resultados obtenidos del análisis de las treinta y una fuentes revisadas entre 2021 y 2025 permiten identificar una amplia gama de aplicaciones de inteligencia artificial orientadas a la reducción de la huella de carbono en sistemas computacionales. En los estudios analizados se observa que los enfoques más recurrentes son el aprendizaje automático y profundo, el aprendizaje por refuerzo, los algoritmos de optimización híbridos y las redes neuronales combinadas con modelos de evaluación de ciclo de vida. Estas técnicas se aplican principalmente en la gestión inteligente de energía en edificios [9], [10], [11], [12], en el control adaptativo de sistemas HVAC y micro redes [13], [14], [15], [16], [17], así como en la optimización de recursos en centros de datos mediante algoritmos evolutivos y de polinización de flores basados en conocimiento [18], [19], [20], [21]. Asimismo, se evidencia el uso de modelos neuronales predictivos en entornos industriales y agrícolas para estimar emisiones y optimizar el consumo energético [22], [23], [24]. En conjunto, estas investigaciones muestran que las soluciones basadas en IA superan a los métodos tradicionales de control y regresión al ofrecer una respuesta dinámica, predictiva y de autoajuste frente a variaciones de carga o demanda energética. En el caso de los centros de datos, por ejemplo, los modelos de aprendizaje por refuerzo profundo han permitido reducir el consumo eléctrico en hasta un 15–25 % mediante estrategias de optimización continua [25], [26], [27]. De modo similar, los sistemas inteligentes de control térmico y ventilación en edificaciones han reportado mejoras sustanciales en la eficiencia energética, alcanzando disminuciones de hasta un 20 % en emisiones de CO₂. En síntesis, los hallazgos confirman que la inteligencia artificial cumple un papel determinante en la transición hacia infraestructuras computacionales sostenibles, pues permite la gestión proactiva de la energía, como también la reducción de pérdidas operativas y la adopción de estrategias digitales alineadas con la sostenibilidad ambiental. En la Figura 2 se representa de forma conceptual los ámbitos tecnológicos donde estas soluciones han mostrado mayor impacto.




Fig. 2 Distribución porcentual de las aplicaciones de IA en la reducción de la huella de carbono.

RQ2: ¿Qué impacto tienen estas aplicaciones en la eficiencia energética y en la reducción de emisiones de carbono?

A lo largo del análisis de las 31 fuentes revisadas, se evidenció que la inteligencia artificial ha generado impactos positivos y cuantificables en la eficiencia energética y la reducción de emisiones de carbono, con resultados variables según el sector y la tecnología aplicada. En promedio, los estudios reportaron mejoras de entre 15 % y 45 % en la eficiencia energética y reducciones de hasta 30 % en las emisiones de CO₂, dependiendo del modelo de IA implementado y del contexto tecnológico. Por ejemplo, investigaciones en centros de datos y entornos cloud computing como las de [9], [14], [28], [23] y [29] destacaron que los algoritmos de optimización multiobjetivo (como EMO-TS y KB-FPA) lograron reducir el consumo eléctrico mediante una gestión dinámica de cargas, alcanzando una disminución media del 25 % en el gasto energético y extendiendo la vida útil de los servidores. En paralelo, estudios sobre redes eléctricas inteligentes y sistemas de energía renovable [19], [30], [31], [32] demostraron que los modelos predictivos basados en aprendizaje profundo (Deep Reinforcement Learning, LSTM y redes neuronales híbridas) permiten ajustar la oferta y demanda energética en tiempo real, logrando una reducción de emisiones de carbono entre 18 % y 40 %, gracias a la optimización del uso de recursos renovables y al control automatizado de cargas.

En el caso de los edificios inteligentes y la gestión térmica de interiores, investigaciones como [33] y [17] evidencian que los modelos de predicción de temperatura basados en aprendizaje automático pueden mejorar la eficiencia del sistema HVAC hasta en un 35 %, lo que se traduce en reducciones significativas de energía y huella de carbono. A nivel industrial, trabajos como [34] y [24] muestran cómo los sistemas de gemelos digitales (digital twins) y plataformas inteligentes de gestión de datos de carbono en parques industriales han conseguido disminuir la

intensidad energética en un 22 %, mediante simulaciones basadas en IA que optimizan los procesos productivos. En el ámbito del transporte y la logística verde, [35] reporta una mejora del 28 % en eficiencia operativa de los puertos inteligentes y una disminución de 20 % en emisiones derivadas de la optimización de rutas y consumo de combustible.

A pesar de los logros, varios estudios (como [10], [36], [16], [27]) señalan que el impacto ambiental neto de la IA depende también del consumo energético de los propios modelos de aprendizaje profundo, especialmente en fases de entrenamiento, por lo que se recomienda la adopción de IA verde (Green AI) y estrategias de aprendizaje eficiente en energía. De manera general, se observa una tendencia clara hacia la integración de IA en la transición energética digital, consolidando su rol como tecnología clave para los Objetivos de Desarrollo Sostenible (ODS 7 y 13).




Fig. 3 Impacto promedio de la IA en la eficiencia energética y la reducción de emisiones según sector.

RQ3: ¿Cómo se comparan los enfoques basados en IA con los métodos tradicionales de optimización en cuanto a efectividad y sostenibilidad?

Los resultados de la revisión sistemática indican que los enfoques basados en inteligencia artificial muestran una ventaja significativamente superior cuando se comparan directamente con escenarios donde no se utiliza IA, es decir, cuando se emplean métodos tradicionales de optimización como heurísticas deterministas, reglas estáticas o modelos lineales rígidos. En los estudios analizados, los sistemas sin IA dependen de configuraciones manuales y respuestas predefinidas, lo que limita su capacidad para adaptarse a variaciones en la carga energética o en la disponibilidad de recursos, reduciendo así su efectividad en la mitigación de la huella de carbono [25], [18], [23], [37], [32].

En cambio, cuando se introduce IA especialmente modelos como *Deep Reinforcement Learning*, redes

neuronales recurrentes y sistemas híbridos predictivo-reactivos la eficiencia energética mejora sustancialmente, duplicando o incluso triplicando los resultados de los enfoques no inteligentes, con reducciones del 25–35 % en consumo energético frente al 10–15 % de los métodos sin IA [13], [24], [19]. Esta brecha es aún más evidente en edificios inteligentes, redes eléctricas y centros de datos, donde las técnicas tradicionales no pueden realizar ajustes continuos ni prever picos de demanda, mientras que la IA sí lo hace al aprender del comportamiento histórico y del contexto operacional [30], [16], [38]. Además, los métodos sin IA no integran modelos de optimización ambiental ni predicción de emisiones, limitando la sostenibilidad del sistema, mientras que los sistemas basados en IA implementan funciones objetivos múltiples que equilibran ahorro energético y reducción de carbono [39], [28], [35].

La evidencia reunida y sintetizada en la Figura 3 confirma que la IA no solo supera a los métodos tradicionales en eficiencia operativa, sino que también ofrece una mejora global del 37 % en sostenibilidad energética, validando que su incorporación es clave cuando se la compara directamente con escenarios donde la IA no está presente.




Fig. 4 Comparación entre enfoques basados en IA y métodos tradicionales de optimización.

RQ4: ¿En qué contextos tecnológicos (centros de datos, cloud computing, software verde, hardware especializado) se han implementado con mayor éxito estas soluciones?

El análisis integral de las 31 fuentes revisadas revela que las soluciones basadas en inteligencia artificial han tenido mayor éxito en los centros de datos y entornos de cloud computing, seguidos por el software verde y, en menor medida, el hardware especializado. En los centros de datos, los modelos de Deep Reinforcement Learning (DRL), algoritmos de optimización evolutiva y redes neuronales convolucionales han permitido reducir hasta un 35 % del

consumo energético total, optimizando el enfriamiento y la distribución de carga [22], [34], [37], [31], [29]. En el contexto del cloud computing, las estrategias de IA se aplican con efectividad en la gestión dinámica de tareas, el balanceo de carga y la predicción de la demanda, logrando un incremento del 32 % en la eficiencia de recursos virtualizados [11], [15], [32], [17]. Esta tendencia es confirmada desde IEEE Xplore por Jayanetti et al. [40], quienes propusieron un marco de aprendizaje por refuerzo profundo multiagente (MAAC) para la planificación de flujos de trabajo en centros de datos cloud distribuidos con fuentes de energía renovable, demostrando mejoras significativas en eficiencia energética y reducción de la huella de carbono en entornos multicloud de alta complejidad. Por su parte, el software verde ha incorporado sistemas de aprendizaje profundo que ajustan el consumo de energía de aplicaciones en tiempo real, logrando reducciones del 20–25 % en consumo eléctrico [14], [28], [12]. En cambio, el hardware especializado, aunque emergente, muestra un impacto positivo al integrar chips de IA con unidades tensoriales de bajo consumo, reduciendo el gasto energético en un 15 % promedio, pero aún con limitaciones de costo y escalabilidad [23], [27], [24].

En conjunto, los resultados demuestran que la aplicación de IA en infraestructura digital tiene mayor madurez en los ámbitos de software y servicios distribuidos, mientras que el hardware aún se encuentra en una etapa de consolidación experimental. La Figura 5 resume estos hallazgos mediante la proporción de éxito alcanzada por cada contexto tecnológico en la implementación de soluciones sostenibles basadas en IA.




Fig. 5 Éxito relativo de la implementación de IA en distintos contextos tecnológicos.

RQ5: ¿Qué limitaciones y desafíos han sido identificados en la literatura sobre el uso de IA para reducir la huella de carbono en sistemas computacionales?

El examen transversal de los artículos revisados evidencia que, aunque las aplicaciones de inteligencia artificial muestran un alto potencial para mejorar la

sostenibilidad digital, su adopción enfrenta importantes limitaciones técnicas, económicas y éticas. En el plano técnico, se observa una dependencia elevada de grandes volúmenes de datos y un consumo energético considerable durante el entrenamiento de modelos de aprendizaje profundo, lo que puede contradecir los objetivos de sostenibilidad [14], [22], [23], [19]. En este sentido, Strubell et al. [41] fueron pioneros en cuantificar el costo financiero y ambiental del entrenamiento de modelos de redes neuronales a gran escala, demostrando que entrenar un único modelo Transformer puede generar emisiones de CO₂ equivalentes a las de cinco automóviles a lo largo de toda su vida útil, lo que subraya la necesidad de incorporar criterios energéticos desde el diseño de los modelos de IA. Además, los algoritmos requieren ajustes continuos para adaptarse a la variabilidad de las condiciones energéticas y a la heterogeneidad de los sistemas computacionales, lo que limita su portabilidad y escalabilidad [34], [15], [30]. En el aspecto económico, los altos costos de implementación, infraestructura y mantenimiento de sistemas de IA avanzados dificultan su aplicación en entornos industriales y públicos con recursos limitados [11], [35], [24], [12]. Desde una perspectiva ambiental, la producción y sustitución de hardware especializado genera impactos indirectos en la cadena de suministro, aumentando las emisiones de carbono asociadas [27], [37], [31].

Finalmente, en el ámbito ético y de gobernanza, la falta de estándares internacionales para medir la huella de carbono digital y la escasa transparencia en el uso de datos de entrenamiento siguen siendo desafíos pendientes [16], [29], [33], [21]. Estos hallazgos muestran que, si bien la IA ofrece ventajas sustanciales en eficiencia energética, su consolidación como herramienta sostenible requiere de marcos regulatorios, optimización de algoritmos verdes y una mayor integración con energías renovables.




Fig. 6 Distribución porcentual de las principales limitaciones identificadas en el uso de IA para la reducción de la huella de carbono.

I. DISCUSIÓN

Los resultados de la revisión sugieren que las aplicaciones de

inteligencia artificial (IA) se están consolidando como la estrategia más efectiva para reducir la huella de carbono en sistemas computacionales, tanto por su capacidad predictiva como por su potencial de optimización dinámica. En primer lugar, la evidencia más sólida se concentra en entornos de centros de datos y cloud computing, donde métodos como la optimización multiobjetivo (EMO-TS) y marcos de aprendizaje por refuerzo profundo (CFWS) han demostrado reducciones de consumo eléctrico y de coste energético relevantes, con cifras reportadas en varios estudios que oscilan en torno a reducciones medias del 25 % y picos de hasta el 35 % en condiciones optimizadas [13], [25]. Esta supremacía se explica porque estas infraestructuras reúnen datos operativos en volumen y velocidad suficientes para que los modelos de IA aprendan patrones de uso y apliquen políticas adaptativas de asignación de recursos y control térmico, logrando una mejora integrada en eficiencia y emisiones [13], [25], [19].

En segundo lugar, la optimización del diseño mismo de modelos e infraestructuras resultan determinante: estrategias arquitectónicas como "Just in Time" que permiten configurar dinámicamente el costo computacional de modelos de IA, disminuyendo el consumo en entrenamiento e inferencia y, por esto, la huella asociada a cargas de trabajo de IA intensivas [11]. Añadiendo, los algoritmos híbridos y bioinspirados como KB-FPA han mostrado eficacia práctica en la gestión de tareas y la asignación eficiente de recursos en nubes y entornos virtualizados, permitiendo minimizar sobreutilización de CPU y memoria y, como resultado, reducir el gasto energético total del servicio [28]. Estas aproximaciones, combinadas con políticas carbon-aware de scheduling, consolidan un doble beneficio: eficiencia operativa y reducción de emisiones [28], [19].

En tercer lugar, el alcance de la IA se extiende fuera del puro dominio virtual: plataformas basadas en gemelos digitales y gestión de datos de carbono (digital twins) facilitan mediciones en tiempo real y simulaciones que permiten acciones correctivas en parques industriales y microneces, reduciendo la intensidad energética de procesos productivos y la emisión de CO₂ mediante optimización basada en datos empíricos [39], [36]. Los casos de microgrids muestran que la combinación de predicción de demanda y control automático de recursos renovables puede traducirse en mejoras sustantivas en eficiencia, lo cual confirma la utilidad de la IA en escenarios ciberfísicos donde la interacción entre software y hardware es crítica [36], [39].

Aunque estos beneficios, la revisión también identificó limitaciones sustantivas que matizan la interpretación de los resultados. En primer lugar, los modelos complejos consumen energía durante su entrenamiento; sin gestión cuidadosa, el coste energético del propio modelo puede atenuar los beneficios netos en emisiones, una observación presente en varios trabajos que recomiendan prácticas de "Green AI" y

estrategias de entrenamiento eficiente [10], [11]. En segundo lugar, la generalización y la portabilidad de modelos sigue siendo un reto: lo que funciona en un centro de datos con cierto perfil de carga puede no transferirse de forma directa a otra infraestructura sin reentrenamiento o ajuste fino [26]. En tercer lugar, existen barreras económicas y de adopción: costes de infraestructura, inversión en hardware especializado y soporte operativo que limitan la escalabilidad de soluciones, particularmente en contextos con recursos financieros reducidos [28], [35].

Por último, la convergencia de estas evidencias sugiere líneas claras de investigación y acción práctica: (a) promover arquitecturas de IA que reduzcan su coste energético (p. ej.

JIT Transformers, sparsity, quantization); (b) integrar políticas carbon-aware en los schedulers de cloud y edge; (c) combinar modelos predictivos con digital twins para cerrar el ciclo medición-acción en infraestructuras físicas; y (d) impulsar métricas estandarizadas de evaluación de huella digital que permitan comparar estrategias. Estas recomendaciones derivan directamente de las fortalezas y limitaciones encontradas en los estudios seleccionados y constituyen una hoja de ruta prioritaria para avanzar hacia infraestructuras computacionales con menor huella de carbono [13], [25], [39], [11], [28], [19], [32].

II. CONCLUSIONES

Esta revisión sistemática demostró de manera integral cómo las aplicaciones de la inteligencia artificial en sistemas computacionales contribuyen a la reducción de la huella de carbono y a la optimización energética, en comparación con los métodos tradicionales de gestión y optimización. Los resultados que se obtuvieron confirmaron que la IA se ha consolidado como una estrategia eficaz para poder mejorar la sostenibilidad digital, debido a su capacidad para identificar patrones, optimizar procesos y gestionar dinámicamente los recursos energéticos en diversos contextos tecnológicos. Los hallazgos evidencian que las técnicas de IA más utilizadas como el aprendizaje automático, el aprendizaje profundo, los algoritmos evolutivos, los modelos predictivos y los enfoques híbridos logran mejoras significativas en la eficiencia energética, reducciones en el consumo eléctrico y disminuciones cuantificables de emisiones de CO₂. Asimismo, se observa que los contextos donde estas soluciones han alcanzado mayor experiencia son los centros de datos, el cloud computing y las infraestructuras digitales distribuidas, mientras que las aplicaciones basadas en hardware especializado se encuentran en una etapa más emergente de consolidación. La revisión también demuestra que la IA supera a los métodos tradicionales en escenarios donde la variabilidad de la demanda, la operación en tiempo real y la complejidad de la infraestructura necesitan de soluciones adaptativas y de alta precisión operativa. La contribución principal de esta revisión radica en sintetizar de

forma comparativa el estado del conocimiento sobre la IA aplicada a la sostenibilidad computacional, clasificando tendencias, patrones, brechas y desafíos que orientan el futuro de esta línea de investigación. En particular, se identifican áreas clave como la necesidad de algoritmos más eficientes energéticamente, la integración con energías renovables, la mejora de la portabilidad de modelos y la adopción de estrategias computacionales más responsables y alineadas con los Objetivos de Desarrollo Sostenible. No obstante, este estudio presenta limitaciones asociadas al rango temporal analizado, la restricción a bases de datos específicas, la exclusión de estudios no empíricos y la variabilidad en los enfoques metodológicos de los artículos revisados. Estas limitaciones pueden influir en la generalización de los resultados y en la amplitud de la evidencia disponible. Finalmente, los resultados permiten señalar que futuras investigaciones deberían profundizar en el desarrollo de técnicas híbridas de IA con menor costo energético, evaluar la sostenibilidad a largo plazo de los modelos aplicados en infraestructura digital, explorar la integración de la IA con sistemas de energía renovable y ampliar los estudios en entornos emergentes como edge computing, smart grids y sistemas inteligentes distribuidos. Estas líneas de trabajo resultan esenciales para avanzar hacia una computación más eficiente, sostenible y alineada con las demandas energéticas del futuro.

De manera aplicada, sería importante investigar aplicaciones específicas como la optimización del consumo energético en centros de datos, la predicción de la demanda en redes eléctricas inteligentes y la gestión eficiente del tráfico urbano mediante modelos de IA.

Referencias

- [1] J. Tang, K. Huang, and A. Xiong, "Impact of digital transformation on corporate sustainability: Evidence from China's carbon emissions," *Energy Informatics*, vol. 8, no. 1, p. 79, 2025, doi: 10.1186/s42162-025-00479-8
- [2] R. Henao, R. Edgell, A. Sharma, and J. Olney, "AI in power systems: A systematic review of key matters of concern," *Energy Informatics*, vol. 8, no. 1, p. 25, 2025, doi: 10.1186/s42162-025-00529-1.
- [3] F. Li, J. Tao, Q. Wang, Q. Guo, X. Wang, B. Wang, H. Su, Z. Yan, and B. Chen, "Simulation and optimization of cold chain logistics system towards low carbon emission: A state-of-the-art review," *Carbon Research*, vol. 4, no. 1, p. 1, 2025, doi: 10.1007/s44246-024-00191-4.
- [4] S. Park, I.-B. Lee, J. Seo, U.-H. Yeo, J.-H. Cho, and C. Decano-Valentin, "Ventilation rate prediction in naturally ventilated greenhouses using a CFD-driven machine learning model," *Journal of the ASABE*, vol. 68, no. 4, pp. 573–589, 2025, doi: 10.13031/ja.15896.
- [5] L. Lei, T. Wu, S. Shi, Y. Si, C. Zhi, K. Huang, J. Yang, X. Liang, S. Zhu, J. Qu, and J. Hu, "Engineered radiative cooling systems for thermal-regulating and energy-saving applications," *Nano-Micro Letters*, vol. 18, no. 1, p. 18, 2024, doi: 10.1007/s40820-025-01859-1.
- [6] B. Kitchenham and S. Charters, "Guidelines for performing Systematic Literature Reviews in Software Engineering," Dept. Comput. Sci., Univ. Durham, Durham, U.K., Tech. Rep. EBSE-2007-01, 2007.
- [7] H. Snyder, "Literature review as a research methodology: An overview and guidelines," *Journal of Business Research*, vol. 104, pp. 333–339, 2019, doi: 10.1016/j.jbusres.2019.07.039.
- [8] M. J. Page et al., "PRISMA 2020 explanation and elaboration: Updated guidance and exemplars for reporting systematic reviews," *BMJ*, vol. 372, p. n71, Mar. 2021.
- [9] G. Papa, R. Hribar, G. Petelin, and V. Vukašinović, "Advanced computing to support urban climate neutrality," *Energy, Sustainability and Society*, 2025, doi: 10.1186/s13705-025-00517-z.
- [10] F. Islam, I. Ahmed, and L. N. Mihet-Popa, "Development and testing of an IoT platform with smart algorithms for building energy management systems," *Energy & Buildings*, 2025, doi: 10.1016/j.enbuild.2025.115970.
- [11] P. Rajaram and O. V. Gnana Swathika, "Data-driven predictive models for sustainable smart buildings," *Results in Engineering*, vol. 27, 2025, Art. 105916, doi: 10.1016/j.rineng.2025.105916.
- [12] E. Assareh, N. Izadyar, E. Jamei, M. A. Monzavian, S. Agarwal, and N. Agarwal, "Optimizing solar-powered multi-generation systems for sustainable energy management in university buildings using Neural Networks and Genetic Algorithms," *Journal of Building Engineering*, 2025, doi: 10.1016/j.jobe.2025.112939.
- [13] W. Lu, Y. Gao, Z. Sun, and Q. Mao, "An improved soft actor-critic framework for cooperative energy management in the building cluster," *Applied Sciences*, vol. 15, no. 16, Art. 8966, 2025, doi: 10.3390/app15168966.
- [14] A. Madiyev, D. Bulegenov, A. Karzhaubayev, M. Murzabulatov, and D. M. Bui, "Energy-efficient offloading framework for mobile edge/cloud computing based on convex optimization and Deep Q-Network," *The Journal of Supercomputing*, 2025, doi: 10.1007/s11227-025-07647-3.
- [15] S. M. Moghimi, T. A. Gulliver, I. Thirumarai-Chelvan, and H. Teimoorinia, "Occupant-centric load optimization in smart green townhouses using machine learning," *Energies*, 2025, doi: 10.3390/en18133320.
- [16] S. H. Godasiaei, O. A. Ejohwomu, H. Zhong, and D. R. Booker, "Integrating experimental analysis and machine learning for enhancing energy efficiency and indoor air quality in educational buildings," *Building and Environment*, 2025, doi: 10.1016/j.buildenv.2025.112874.
- [17] J. Chen, J. Mi, C. Guo, Q. Fu, W. Tang, W. Luo, and Q. Zhu, "Research on offloading and resource allocation for MEC with energy harvesting based on deep reinforcement learning," *Electronics*, vol. 14, no. 10, 2025, doi: 10.3390/electronics14101911.
- [18] M. Alghieth, "Sustain AI: a multi-modal deep learning framework for carbon footprint reduction in industrial manufacturing," *Sustainability*, vol. 17, no. 9, 2025, doi: 10.3390/su17094134.
- [19] S. Mirasçı, S. Uygur, and A. Aksoy, "Advancing energy efficiency: Machine learning based forecasting models for integrated power systems in food processing company," *International Journal of Electrical Power & Energy Systems*, 2025, doi: 10.1016/j.ijepes.2024.110445.
- [20] Y. A. Khan, F. A. Kateb, A. U. Rehman et al., "Enhancing smart home efficiency with heuristic-based energy optimization," *Computers*, 2025, doi: 10.3390/computers14040149.
- [21] Z. Zhao, M. Wang, J. Wei et al., "Interpretable machine learning for multi-energy supply station revenue forecasting: a SHAP-driven framework to accelerate urban carbon neutrality," *Energies*, 2025, doi: 10.3390/en18071624.
- [22] P. T. Michailidis, I. T. Michailidis, and E. B. Kosmatopoulos, "Reinforcement learning for optimizing renewable energy utilization in buildings: a review on applications and innovations," *Energies*, 2025, doi: 10.3390/en18071724.
- [23] M. G. Gronfala and K. F. Sayed, "AI-driven predictive control for dynamic energy optimization in flying cars," *Energies*, 2025, doi: 10.3390/en18071781.
- [24] C. Kim, K. Cho, and I. Joe, "Artificial intelligence-based fault diagnosis for steam traps using statistical time series features and a transformer encoder-decoder model," *Electronics*, 2025, doi: 10.3390/electronics14051010.
- [25] H. Sun, Y. Hu, J. Luo, Q. Guo, and J. Zhao, "Enhancing HVAC control systems using a steady soft actor-critic deep reinforcement learning approach," *Buildings*, vol. 15, no. 4, 2025, doi: 10.3390/buildings15040644.
- [26] S. Nambi and P. Thanapal, "EMO-TS: an enhanced multi-objective optimization algorithm for energy-efficient task scheduling in cloud data centers," *IEEE Access*, 2025, doi: 10.1109/ACCESS.2025.3527031.

- [27] M. M. Alam, M. J. Hossain, M. A. Zamee, and A. Al-Durra, "Design and operation of future low-voltage community microgrids: an AI-based approach with real case study," *Applied Energy*, 2025, doi: 10.1016/j.apenergy.2024.124523.
- [28] D. Zhao, J. Zhou, and K. Li, "CFWS: DRL-based framework for energy cost and carbon footprint optimization in cloud data centers," *IEEE Transactions on Sustainable Computing*, 2025, doi: 10.1109/TSUSC.2024.3391791.
- [29] E. Ji, Y. Wang, S. Xing, and J. Jin, "Hierarchical reinforcement learning for energy-efficient API traffic optimization in large-scale advertising systems," *IEEE Access*, 2025, doi: 10.1109/ACCESS.2025.3598712.
- [30] L. Wang, H. Wang, Y. Li *et al.*, "The design and implementation of an intelligent carbon data management platform for digital twin industrial parks," *Energies*, 2024, doi: 10.3390/en17235972.
- [31] I. Mehdi, A. Chmarkhi, M. Ammari, and L. Ben Allal, "Combined application of life cycle assessment and neural network model for modeling energy and environmental emissions in sugar beet production," *Results in Engineering*, 2024, doi: 10.1016/j.rineng.2024.103356.
- [32] I. Durluk, T. I. Miller, E. Kostecka *et al.*, "Harnessing AI for sustainable shipping and green ports: challenges and opportunities," *Applied Sciences*, 2024, doi: 10.3390/app14145994.
- [33] A. A. E. Benali, M. Cafaro, I. Epicoco, M. Pulimeno, and E. J. Schioppa, "Just in time transformers," *IEEE Access*, 2024, doi: 10.1109/ACCESS.2024.3504862.
- [34] N. Chauhan, N. Kaur, K. S. Saini *et al.*, "Maximizing resource efficiency in cloud data centers through knowledge-based flower pollination algorithm (KB-FPA)," *computer Materials & Continua*, 2024, doi:10.32604/cmc.2024.046516.
- [35] A. A. Amer, I. E. Talkhan, R. F. Ahmed, and T. Ismail, "An optimized collaborative scheduling algorithm for prioritized tasks with shared resources in mobile-edge and cloud computing systems," *Mobile Networks and Applications*, 2022, doi: 10.1007/s11036-022-01974-y.
- [36] S. Alawadi, D. Mera, M. Fernández-Delgado *et al.*, "A comparison of machine learning algorithms for forecasting indoor temperature in smart buildings," *Energy Systems*, 2022, doi: 10.1007/s12667-020-00376-x.
- [37] H. U. Gökçe and K. U. Gökçe, "Intelligent energy optimization system development and validation for German building types," *International Journal of Low-Carbon Technologies*, 2021, doi: 10.1093/ijlct/ctab049.
- [38] A. Kumar, M. Alaraj, M. Rizwan, and U. Nangia, "Novel AI based energy management system for smart grid with RES integration," *IEEE Access*, 2021, doi: 10.1109/ACCESS.2021.3131502.
- [39] H. W. Khan, M. Usman, G. Hafeez, F. R. H. Albogamy, I. Khan, Z. Shafiq, M. U. A. Khan, and H. I. Alkhamash, "Intelligent optimization framework for efficient demand-side management in renewable energy integrated smart grid," *IEEE Access*, 2021, doi: 10.1109/ACCESS.2021.3109136.
- [40] A. Jayanetti, S. Halgamuge, and R. Buyya, "Multi-Agent deep reinforcement learning framework for renewable Energy-Aware workflow scheduling on distributed cloud data centers," *IEEE Transactions on Parallel and Distributed Systems*, vol. 35, no. 4, pp. 604–615, Jan. 2024, doi: 10.1109/tpds.2024.3360448.
- [41] E. Strubell, A. Ganesh, and A. McCallum, "Energy and Policy Considerations for Deep Learning in NLP," *Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics*, pp. 3645–3650, Jan. 2019, doi: 10.18653/v1/p19-1355