

EVOLUCIÓN DE LA INTELIGENCIA ARTIFICIAL Y SU IMPACTO EN LA ERA CONTEMPORÁNEA EVOLUTION OF ARTIFICIAL INTELLIGENCE AND ITS IMPACT IN THE CONTEMPORARY ERA

Autor: ¹Exer Stalin Loor Beltrón y ²Ricardo Orlando Malla Valdiviezo.

¹ORCID ID: <https://orcid.org/0009-0005-9876-6155>

²ORCID ID: <https://orcid.org/0000-0003-0841-7495>

¹E-mail de contacto: eloor2985@utm.edu.ec

²E-mail de contacto: eloor2985@utm.edu.ec

Afiliación: ^{1*2*}Universidad Técnica de Manabí, (Ecuador).

Artículo recibido: 12 de Febrero del 2026

Artículo revisado: 15 de Febrero del 2026

Artículo aprobado: 20 de Febrero del 2026

¹Egresado de la carrera de Ingeniería en Tecnologías de la Información de la Universidad Técnica de Manabí, (Ecuador).

²Docente de la carrera de Ingeniería en Tecnologías de la Información de la Universidad Técnica de Manabí, (Ecuador).

Resumen

La inteligencia artificial ha experimentado una evolución histórica caracterizada por ciclos de avance y estancamiento, hasta consolidarse en la era contemporánea como una tecnología de impacto transversal. El objetivo de este artículo es analizar el impacto de la inteligencia artificial desde una perspectiva crítica, con énfasis en la sostenibilidad computacional y ambiental de los modelos de lenguaje de gran escala. La investigación se desarrolló mediante una metodología de revisión bibliográfica cualitativa y comparativa, basada en el análisis de aproximadamente 30 documentos especializados, entre artículos científicos e informes técnicos publicados a partir de 2019. Los resultados evidencian que el impacto ambiental de estos sistemas es significativo y de carácter multifactorial, determinado no solo por el tamaño de los modelos, sino también por factores como la matriz energética empleada, la eficiencia algorítmica y los patrones de uso asociados a su despliegue. El análisis comparativo de modelos como ChatGPT, Gemini, Copilot, Llama 3, BLOOM, DeepSeek y xAI (Grok) revela diferencias sustanciales en términos de consumo energético y huella de carbono, así como enfoques contrastantes en materia de transparencia y mitigación de impactos ambientales.

Se concluye que la sostenibilidad futura de la inteligencia artificial no dependerá exclusivamente del acceso a fuentes de energía limpia, sino de una transición hacia

arquitecturas algorítmicas más eficientes, una mayor transparencia en la medición de impactos y la implementación de marcos de gobernanza tecnológica que contribuyan a mitigar los riesgos ambientales y sociales asociados a su adopción masiva.

Palabras clave: Inteligencia artificial, Sostenibilidad computacional, Impacto ambiental, Modelos de lenguaje, Eficiencia energética, Huella de carbono, Gobernanza tecnológica.

Abstract

Artificial intelligence has undergone a historical evolution characterized by cycles of advancement and stagnation, until it became established in the contemporary era as a technology with a transversal impact. The objective of this article is to analyze the impact of artificial intelligence from a critical perspective, with an emphasis on the computational and environmental sustainability of large-scale language models. The research was conducted using a qualitative and comparative bibliographic review methodology, based on the analysis of approximately 30 specialized documents, including scientific articles and technical reports published since 2019. The results show that the environmental impact of these systems is significant and multifactorial, determined not only by the size of the models but also by factors such as the energy matrix used, algorithmic efficiency, and usage patterns associated with their deployment. The

comparative analysis of models such as ChatGPT, Gemini, Copilot, Llama 3, BLOOM, DeepSeek, and xAI (Grok) reveals substantial differences in terms of energy consumption and carbon footprint, as well as contrasting approaches in terms of transparency and environmental impact mitigation. It is concluded that the future sustainability of artificial intelligence will not depend exclusively on access to clean energy sources, but rather on a transition toward more efficient algorithmic architectures, greater transparency in impact measurement, and the implementation of technological governance frameworks that help mitigate the environmental and social risks associated with its massive adoption.

Keywords: Artificial intelligence, Computational sustainability, Environmental impact, Language models, Energy efficiency, Carbon footprint, Technological governance.

Sumário

A inteligência artificial tem experimentado uma evolução histórica caracterizada por ciclos de avanço e estagnação, até se consolidar na era contemporânea como uma tecnologia de impacto transversal. O objetivo deste artigo é analisar o impacto da inteligência artificial a partir de uma perspectiva crítica, com ênfase na sustentabilidade computacional e ambiental dos modelos de linguagem de grande escala. A pesquisa foi desenvolvida por meio de uma metodologia de revisão bibliográfica qualitativa e comparativa, baseada na análise de aproximadamente 30 documentos especializados, entre artigos científicos e relatórios técnicos publicados a partir de 2019. Os resultados evidenciam que o impacto ambiental desses sistemas é significativo e de caráter multifatorial, determinado não apenas pelo tamanho dos modelos, mas também por fatores como a matriz energética empregada, a eficiência algorítmica e os padrões de uso associados ao seu despliegue. A análise comparativa de modelos como ChatGPT, Gemini, Copilot, Llama 3, BLOOM, DeepSeek e xAI (Grok) revela diferenças substanciais em

termos de consumo energético e pegada de carbono, bem como abordagens contrastantes em matéria de transparência e mitigação de impactos ambientais.

Conclui-se que a sustentabilidade futura da inteligência artificial não dependerá exclusivamente do acesso a fontes de energia limpa, mas sim de uma transição para arquiteturas algorítmicas mais eficientes, uma maior transparência na medição de impactos e a implementação de marcos de governança tecnológica que contribuam para mitigar os riscos ambientais e sociais associados à sua adoção em massa.

Palavras-chave: Inteligência artificial, Sustentabilidade computacional, Impacto ambiental, Modelos de linguagem, Eficiência energética, Pegada de carbono, Governança tecnológica.

Introducción

La investigación en inteligencia artificial (IA) se configura como un campo en constante expansión, caracterizado por una rápida evolución técnica y por la convergencia de enfoques teóricos, metodológicos y éticos. En las últimas décadas, la IA ha dejado de concebirse como un ideal abstracto para consolidarse como una tecnología transversal, integrada de forma creciente en la ciencia, la economía y la organización social. No obstante, a pesar de la abundancia de estudios centrados en sus fundamentos computacionales y en sus aplicaciones prácticas, la literatura evidencia persistentes vacíos analíticos en la articulación histórica, social y crítica de su desarrollo. Esta fragmentación limita una comprensión integral del impacto de la inteligencia artificial en la era contemporánea y justifica la necesidad de revisiones que integren las dimensiones técnica, histórica y socioeconómica del fenómeno.

La evolución histórica de la inteligencia artificial ha sido ampliamente documentada por diversos autores. Abeliuk y Gutiérrez (2021) presentan una recopilación de los principales

hitos del campo, desde los aportes conceptuales de Ada Lovelace en el siglo XIX hasta el desarrollo de sistemas contemporáneos, destacando eventos fundacionales como la Conferencia de Dartmouth de 1956 y los trabajos pioneros de Alan Newell y Herbert Simon. Las reflexiones de Lovelace sobre la capacidad de las máquinas para operar con símbolos más allá del cálculo numérico constituyen un antecedente conceptual relevante, posteriormente formalizado por Alan Turing en sus planteamientos sobre la computación y la posibilidad de que las máquinas emulen procesos cognitivos. De manera complementaria, León et al. (2024) retoman estos antecedentes, subrayando la visión temprana del potencial computacional que sentó las bases del campo. Sin embargo, estos enfoques se caracterizan por un énfasis predominantemente técnico y cronológico, lo que ha limitado el análisis sistemático de las implicaciones sociales y éticas que han acompañado el desarrollo histórico de la inteligencia artificial.

En el plano conceptual, diversos estudios han profundizado en los fundamentos teóricos de la inteligencia artificial, destacando el aporte de Alan Turing como un punto de inflexión en la consolidación de la disciplina. Robisco (2024) retoma el artículo “Computing Machinery and Intelligence” (1950), en el que Turing formula la célebre pregunta “¿Pueden pensar las máquinas?” y propone el Test de Turing como criterio para evaluar la inteligencia de las máquinas. Estas ideas sentaron las bases del pensamiento algorítmico moderno y contribuyeron a legitimar la inteligencia artificial como un campo científico autónomo. No obstante, gran parte de la literatura que aborda estos fundamentos adopta una visión progresiva y acumulativa del desarrollo tecnológico, omitiendo el análisis de las crisis,

discontinuidades y periodos de estancamiento que también han configurado la trayectoria histórica de la inteligencia artificial.

La evolución de la inteligencia artificial no ha seguido un desarrollo lineal ni continuo, sino que ha estado marcada por ciclos de entusiasmo y desilusión. Diversos estudios identifican estos periodos de estancamiento como los denominados “inviernos de la inteligencia artificial”, caracterizados por una reducción significativa del financiamiento, del interés académico y del desarrollo tecnológico efectivo. (Abeliuk y Gutiérrez, 2021) describen estos episodios como el resultado de expectativas sobredimensionadas respecto a las capacidades reales de la tecnología, lo que generó una brecha persistente entre los avances teóricos y su implementación práctica. Desde una perspectiva más crítica, (Wlach, 2019) interpreta los inviernos de la inteligencia artificial como crisis estructurales derivadas de la disociación entre las promesas formuladas por la comunidad científica y las limitaciones tecnológicas propias de cada contexto histórico. Esta tensión, sumada a la dependencia del financiamiento institucional y a la presión por resultados inmediatos, dio lugar a ciclos recurrentes de expansión y contracción que condicionaron el avance del campo durante varias décadas.

En una lectura contemporánea, Zaikova (2023) revisa el origen del concepto de “invierno de la inteligencia artificial”, señalando que fue acuñado por analogía con el “invierno nuclear” para describir reacciones en cadena provocadas por pronósticos pesimistas que derivaron en una drástica reducción de la inversión y la investigación. No obstante, la autora sostiene que el uso actual del término debe ser matizado, dado que las condiciones institucionales, económicas y sociales que sostienen el

desarrollo tecnológico contemporáneo difieren sustancialmente de las del pasado. En este sentido, propone la noción de “noviembre de la IA” para referirse a posibles fases de desaceleración futura que, sin implicar un colapso del campo, podrían reconfigurar sus ritmos de crecimiento y sus prioridades de investigación. Las limitaciones que caracterizaron a los primeros desarrollos de la inteligencia artificial estuvieron estrechamente vinculadas al reducido poder computacional y a la escasez de grandes volúmenes de datos disponibles. No obstante, a partir de la década de 1990, la incorporación del aprendizaje automático (machine learning) marcó un punto de inflexión en la evolución del campo, al permitir la aplicación efectiva de la IA a problemas del mundo real. Díaz (2021) señala que el aprendizaje automático hizo posible el desarrollo de sistemas capaces de aprender a partir de los datos, superando las restricciones de los enfoques simbólicos tradicionales.

Posteriormente, el auge del aprendizaje profundo (deep learning) consolidó una nueva etapa caracterizada por avances significativos en áreas como el reconocimiento de voz, la visión artificial y el análisis predictivo. A diferencia de los modelos clásicos, las arquitecturas profundas permiten aprender representaciones complejas directamente a partir de grandes volúmenes de información, mejorando su desempeño de manera progresiva. Este cambio de paradigma, junto con el incremento sostenido de la capacidad computacional, consolidó a la inteligencia artificial como una tecnología de impacto transversal en múltiples sectores, al posibilitar avances relevantes en la automatización de procesos y en la toma de decisiones (Abeliuk y Gutiérrez, 2021; León et al., 2024). El desarrollo del aprendizaje profundo y de las redes neuronales artificiales ha permitido la

creación de sistemas con capacidades cognitivas cada vez más sofisticadas. Granados et al. (2019) destacan que estos avances han tenido un impacto significativo en sectores como la salud, donde los modelos predictivos basados en redes neuronales han alcanzado niveles de precisión comparables o superiores a los diagnósticos humanos en tareas específicas. De manera complementaria, (Ortiz Domínguez, 2025) señala que la investigación reciente se ha orientado hacia la diversificación de arquitecturas, incluyendo redes convolucionales, recurrentes y generativas adversariales, lo que ha convertido al aprendizaje profundo en un campo altamente versátil y en constante expansión.

En este contexto, el surgimiento de la inteligencia artificial generativa, impulsada por arquitecturas Transformer, ha redefinido la frontera tecnológica de la disciplina. (Sajun et al., 2024) señalan que modelos como ChatGPT, DALL·E y Gemini han evidenciado capacidades avanzadas para generar texto, imágenes y código con altos niveles de coherencia. La rápida adopción de estas tecnologías ha renovado el interés académico y ha ampliado la presencia de la IA en contextos cotidianos, marcando una nueva etapa en su evolución técnica y sentando las bases para los debates contemporáneos sobre su impacto social, económico y ético. La consolidación de la inteligencia artificial contemporánea, particularmente de las tecnologías basadas en aprendizaje profundo e inteligencia artificial generativa, ha intensificado su impacto en la sociedad actual. Más allá de su dimensión técnica, la IA se ha configurado como un factor de transformación estructural que incide en los ámbitos económico, social, educativo y productivo, redefiniendo procesos, modelos de trabajo y formas de interacción humana. La rápida integración de estos sistemas en

contextos cotidianos y organizacionales ha ampliado el debate académico en torno a sus beneficios, riesgos y desafíos, evidenciando la necesidad de analizar su impacto desde una perspectiva crítica e interdisciplinaria.

La expansión reciente de la inteligencia artificial ha generado un impacto significativo en ámbitos como la educación, la industria y la vida cotidiana. (Pedraza, 2023) analiza este fenómeno destacando los beneficios asociados a la automatización, el aumento de la productividad y la innovación tecnológica, así como los desafíos emergentes vinculados a la transformación del empleo y los dilemas éticos. No obstante, si bien este enfoque resulta relevante para comprender el papel de la inteligencia artificial en la sociedad contemporánea, gran parte de estos análisis se concentra en sus efectos inmediatos, dejando en segundo plano la discusión sobre los paradigmas técnicos que sustentan estos avances y sus implicaciones a largo plazo. El impacto de la inteligencia artificial en el ámbito económico-productivo se manifiesta como un vector de transformación profunda, caracterizado por una dualidad de oportunidades y desafíos. Villagomez (2025) conceptualiza la IA como un motor de crecimiento, eficiencia y optimización, destacando su capacidad para automatizar tareas cognitivas, optimizar procesos y reducir costos operativos, lo que se traduce en incrementos significativos de productividad. Estas dinámicas se materializan en aplicaciones como los sistemas de recomendación, la analítica avanzada para la toma de decisiones y la simulación de escenarios económicos, que otorgan a las organizaciones una ventaja competitiva sostenida.

No obstante, la literatura también advierte sobre los límites estructurales de esta disrupción. La

adopción de la inteligencia artificial no se produce de forma homogénea y puede profundizar las brechas económicas existentes, particularmente entre economías desarrolladas y regiones con menor inversión tecnológica, como América Latina y Centroamérica. Asimismo, se identifican riesgos asociados al uso de algoritmos en prácticas de fijación de precios, los cuales podrían facilitar dinámicas colusorias de difícil detección y afectar negativamente a los consumidores. Incluso en ámbitos consolidados como la gestión financiera, persisten imprecisiones y dependencias críticas de variables como la calidad de los datos, el diseño de los prompts y la versión de las plataformas utilizadas, lo que evidencia que la promesa de una automatización plenamente confiable aún no se ha materializado. En estrecha relación con las transformaciones económicas impulsadas por la inteligencia artificial, su impacto en el mercado laboral configura un escenario complejo y potencialmente disruptivo. Thainá (2025) sostiene que, si bien las ganancias en eficiencia y productividad son evidentes, la automatización de tareas rutinarias y repetitivas afecta de manera directa a sectores como la contabilidad, los servicios de atención al cliente y el transporte. Paralelamente, emergen nuevas oportunidades laborales en áreas especializadas como la ciencia de datos, la ciberseguridad y el desarrollo de sistemas inteligentes, lo que evidencia el carácter dual de esta transición tecnológica.

Desde una perspectiva cuantitativa, este fenómeno adquiere mayor dimensión al considerar las proyecciones sobre el empleo global. De acuerdo con Thainá (2025), citando el informe Futuro do Emprego del Foro Económico Mundial, se estima la desaparición de aproximadamente 85 millones de puestos de trabajo, lo que plantea la necesidad de una

reconversión profunda de la fuerza laboral. Sin embargo, este proceso dista de ser automático o equitativo. La literatura coincide en señalar que la creciente brecha de cualificación constituye uno de los principales desafíos asociados a la automatización, incorporando una dimensión ética relevante: mientras los trabaja-dores con mayores niveles educativos y acceso a recursos presentan mejores condiciones de adaptación, aquellos pertenecientes a los estratos medio y bajo enfrentan mayores riesgos de desempleo prolongado y precarización laboral.

Desde la perspectiva de los estudios sociales de la ciencia y la tecnología, Ruiz y Gastelúa, (2025) sostienen que el desarrollo de la inteligencia artificial no es un proceso neutral, sino que se encuentra en una relación dialéctica constante con factores sociales, políticos y económicos. Esta aproximación subraya la necesidad de establecer marcos regulatorios y de gobernanza que orienten su despliegue y contribuyan a mitigar riesgos como los sesgos algorítmicos y las asimetrías de poder tecnológico. En el ámbito laboral, este debate adquiere especial relevancia. Sanromán (2025) coincide en señalar que, aunque la automatización puede agilizar procesos productivos y generar nuevas oportunidades, también intensifica las percepciones de amenaza asociadas al desempleo y a la precarización del trabajo. Frente a este escenario, una parte significativa de la literatura enfatiza la adaptación proactiva y la capacitación continua como estrategias centrales para enfrentar la transformación del mercado laboral. No obstante, esta postura debe ser matizada a la luz de las barreras estructurales existentes, como el acceso desigual a la educación, la formación técnica y los recursos económicos, que limitan la capacidad de amplios sectores de la población para beneficiarse de dicha transición. En este

sentido, los enfoques de gobernanza de la inteligencia artificial se configuran como un elemento clave para promover una transformación tecnológica más inclusiva y socialmente equitativa.

La incorporación de la inteligencia artificial en los sistemas educativos ha generado un creciente cuerpo de investigación orientado a analizar tanto sus aportes pedagógicos como los riesgos socioeducativos asociados a su implementación. León et al. (2024) identifican tres ámbitos principales de aplicación: la personalización de los procesos de enseñanza-aprendizaje, la optimización de la gestión institucional y la detección temprana de factores de riesgo académico. En particular, los sistemas basados en aprendizaje automático han demostrado capacidad para adaptar contenidos, metodologías y ritmos de aprendizaje a las necesidades individuales de los estudiantes. No obstante, la literatura revisada introduce matices que evitan una visión tecnológicamente determinista. Millán (2025) señala que las mejoras en el rendimiento académico resultan significativas únicamente cuando las herramientas basadas en IA se integran de manera articulada con estrategias pedagógicas lideradas por docentes capacitados. En este sentido, la inteligencia artificial no constituye una solución autónoma, sino un recurso complementario cuya eficacia depende de factores humanos, institucionales y contextuales. Esta condición refuerza el riesgo de que una implementación desigual de la IA en educación profundice las brechas existentes entre instituciones con distintos niveles de recursos y formación docente.

En el ámbito de la salud, la inteligencia artificial ha emergido como una tecnología con potencial transformador tanto en la gestión clínica como en la práctica médica. Cabra (2024) destaca su

capacidad para automatizar tareas administrativas y clínicas rutinarias, lo que contribuye a optimizar los flujos de trabajo institucionales y a liberar tiempo para la atención directa de los pacientes. Asimismo, Guachamboza y Baldeón (2024) subrayan la utilidad de la IA en la determinación de tratamientos personalizados y en áreas especializadas como la pediatría y la cardiología, donde los sistemas inteligentes apoyan el diagnóstico y la toma de decisiones terapéuticas. Sin embargo, la literatura coincide en señalar una limitación estructural: la imposibilidad de sustituir la dimensión humana de la relación médico-paciente. Elementos como la empatía, la intuición clínica y la experiencia profesional continúan siendo atributos irremplazables del personal sanitario. En consecuencia, se consolida un consenso académico que concibe a la inteligencia artificial como una herramienta de apoyo complementaria, cuyo valor reside en su carácter colaborativo y en su subordinación al juicio clínico humano.

La sostenibilidad computacional se ha consolidado como un eje emergente en el análisis del desarrollo y despliegue de sistemas de inteligencia artificial, especialmente en el contexto de los modelos de lenguaje de gran escala. El crecimiento exponencial de estos modelos ha incrementado de manera significativa la demanda de recursos computacionales, caracterizada por un elevado consumo energético, el uso de hardware especializado y la necesidad de capital humano altamente cualificado. Kandpal y Raffel (2025) advierten que los costos asociados al entrenamiento de modelos de gran escala no se limitan al proceso algorítmico, sino que incluyen factores estructurales como la infraestructura computacional y la mano de obra especializada. Desde una perspectiva

ambiental, Zambrano y Cobeña (2025) señalan que el consumo energético asociado al entrenamiento y operación de estos sistemas genera una huella ambiental considerable, incluso cuando se emplean fuentes de energía con menor impacto. En este sentido, la sostenibilidad computacional se configura como un componente clave para evaluar la viabilidad técnica, económica y ética del desarrollo futuro de la inteligencia artificial. En conjunto, la literatura revisada evidencia que la inteligencia artificial contemporánea no puede ser comprendida únicamente desde una perspectiva técnica o instrumental. Su evolución histórica, los ciclos de expansión y estancamiento, el resurgimiento impulsado por el aprendizaje profundo y la IA generativa, así como sus impactos económicos, laborales, educativos, sanitarios y ambientales, configuran un fenómeno complejo y multidimensional. Estos aportes coinciden en señalar que el desarrollo de la inteligencia artificial está profundamente condicionado por factores sociales, políticos y económicos, lo que refuerza la necesidad de abordajes críticos e interdisciplinarios. En este marco, el presente artículo se inscribe en la necesidad de integrar dichas dimensiones para analizar de manera sistemática el impacto de la inteligencia artificial en la era contemporánea.

Materiales y Métodos

El presente trabajo se desarrolló bajo un diseño de investigación no experimental, de enfoque cualitativo, con un alcance descriptivo y comparativo. Se trató de una revisión bibliográfica y documental, orientada al análisis crítico de literatura académica, informes técnicos y reportes institucionales relacionados con el impacto ambiental, la huella de carbono y la sostenibilidad computacional de modelos de inteligencia artificial de gran escala. No se aplicaron pruebas empíricas directas ni experimentos, dado que el objetivo fue

synthesize, compare and interpret secondary information. The study population consisted of scientific publications, technical reports, institutional documents and specialized literature related to the development, training, operation and sustainability of large-scale artificial intelligence models. The sample was non-probabilistic and intentional, selected based on the thematic relevance and quality of the sources. In total, approximately 30 documents were reviewed, including academic articles, preprints and official reports. The inclusion criteria were: (i) publications issued from 2019 onwards to ensure technological relevance; (ii) documents directly related to environmental impact, energy consumption, carbon footprint or computational sustainability of AI models; and (iii) sources in multiple languages (Spanish, English, Portuguese and Russian), prioritizing technical content over the language of publication. Documents of a divulgative nature without technical support and studies prior to 2019 that did not reflect the current state of technology were excluded.

The information collection was carried out through a systematic documentary search in databases and specialized repositories, including Google Scholar, SciELO, Dialnet, arXiv and Semantic Scholar. Although no formal protocol such as PRISMA was applied, the search was structured based on key words and subtopics derived from the study objective, such as large language models, computational sustainability and energy consumption in data centers. The process was iterative, allowing the progressive incorporation of relevant subtopics. In line with the documentary approach, a comparative table (Table 1) was constructed that synthesizes the environmental and

energetic of different AI models. The data analysis was carried out using a qualitative and comparative approach. In the first stage, the documents were classified chronologically to address the historical evolution of artificial intelligence up to contemporary models. Subsequently, a thematic analysis was applied, focusing on environmental, energy and computational impacts associated with each model, contrasting information from different sources to identify similarities, differences and trends. The processing and systematization of the information was carried out manually, using comparison and conceptual synthesis matrices, appropriate to the exploratory and documentary character of the investigation.

Resultados y Discusión

From the literature analyzed, the results allow identifying general patterns around the environmental sustainability of large-scale artificial intelligence models. From the perspective of environmental sustainability, various academic and technical reports coincide in pointing out that large-scale artificial intelligence models require significant quantities of natural resources, particularly electricity and water, which translates into relevant environmental impacts. These impacts are concentrated mainly in the infrastructure of data centers, where operation and refrigeration constitute one of the main energy consumption focuses. In this context, specialized literature highlights the need to implement mitigation strategies, such as the use of renewable energy sources and the optimization of computational infrastructure efficiency.

In terms of carbon footprint, various studies have documented that training

de modelos de lenguaje de gran escala puede generar emisiones de dióxido de carbono comparables a las producidas por comunidades de tamaño medio durante periodos prolongados. Asimismo, se advierte que el impacto ambiental asociado a la inteligencia artificial no se limita a la fase de entrenamiento, sino que se extiende al uso continuo de los modelos en tareas de inferencia, un aspecto que con frecuencia ha sido subestimado en los análisis tradicionales.

Desde el punto de vista energético, la eficiencia de los sistemas de inteligencia artificial depende de múltiples factores, entre los que destacan la localización geográfica de los centros de datos, el tipo de fuentes energéticas empleadas y el grado de optimización del hardware utilizado. En este sentido, la literatura especializada evidencia que el uso de redes eléctricas con baja intensidad de carbono y de infraestructuras energéticas más limpias puede reducir significativamente la huella ambiental de los modelos de gran escala, al mismo tiempo que subraya la importancia de mejorar la eficiencia de los algoritmos y de los dispositivos especializados para disminuir el consumo energético global.

En este sentido, la sostenibilidad computacional emerge como un enfoque orientado a diseñar modelos y sistemas de inteligencia artificial que reduzcan su impacto ambiental sin comprometer de forma significativa su rendimiento. Entre las estrategias más relevantes se identifican el desarrollo de modelos más pequeños y eficientes mediante técnicas como la destilación y la cuantización, el uso compartido de recursos en entornos de computación en la nube y la incorporación de métricas ambientales en los procesos de evaluación de los modelos. En consecuencia, la literatura reciente sugiere que la evaluación de los sistemas de inteligencia artificial debe

ampliarse más allá de métricas tradicionales como la precisión o la velocidad, incorporando de manera explícita consideraciones ambientales y energéticas

En el caso de ChatGPT (OpenAI), la literatura lo identifica como el referente de los modelos generativos de acceso masivo. Los análisis sugieren que su impacto se caracteriza por un consumo dual intensivo: una fase de entrenamiento que demanda recursos energéticos a escala de gigavatios-hora y, de manera crítica, una fase de inferencia continúa sostenida por una base de usuarios global, cuyo consumo hídrico se ha estimado en aproximadamente 500 ml por cada interacción promedio de 20 a 50 turnos (Li et al., 2025). A diferencia de modelos transparentes como BLOOM, la evaluación precisa de su huella de carbono se ve limitada por la naturaleza cerrada de su arquitectura closed source, lo que impide auditorías externas completas (Luccioni et al., 2022). No obstante, los reportes de sostenibilidad de su infraestructura anfitriona (Microsoft Azure) indican un aumento del 34% en el consumo de agua y emisiones asociadas, vinculado directamente a la expansión de estos servicios de IA (Nakagawa y Smith, 2025).

En relación con Gemini, la literatura técnica reciente destaca avances significativos en la medición y mitigación del impacto ambiental de la inteligencia artificial en la fase de inferencia. Los estudios analizados incorporan una evaluación integral del consumo energético, considerando no solo los aceleradores de IA activos, sino también componentes como CPU, memoria, infraestructura de centros de datos y sistemas de refrigeración, lo que permite una estimación más realista del impacto ambiental. Los resultados reportan un consumo aproximado de 0.24 Wh por consulta, lo que representa una eficiencia superior frente a

promedios anteriores, atribuida a la optimización de modelos y uso de TPUs (Elsworth et al., 2025). Cabe señalar que, pese a la eficiencia lograda a nivel individual, la escala masiva de uso convierte a la sostenibilidad computacional en un desafío crítico para este sistema.

En el caso de Microsoft Copilot, los resultados sugieren que su impacto ambiental se encuentra fuertemente condicionado por su integración en entornos productivos. A diferencia de sistemas conversacionales convencionales, Copilot procesa documentos completos y estructuras de datos complejas mediante enfoques de Retrieval Augmented Generation (RAG), lo que incrementa la carga computacional por inferencia y en consecuencia, el consumo energético (Nakagawa y Smith, 2025). La infraestructura de soporte, basada en centros de datos a gran escala, ha implicado un aumento significativo en el consumo de recursos, reportándose un incremento del 34% en la huella hídrica global de la compañía, asociado al crecimiento de las operaciones de inteligencia artificial (Nakagawa y Smith, 2025). Pese a ello se identifican esfuerzos orientados a mitigar este impacto mediante inversiones en fuentes energéticas libres de carbono, incluyendo acuerdos para la reactivación de energía nuclear en Three Mile Island, con el objetivo de garantizar un suministro eléctrico estable y de bajas emisiones. Esta estrategia posiciona a Copilot como un caso relevante de transición hacia una sostenibilidad energética más robusta, aunque los datos actuales aún reflejan el costo ambiental asociado a su despliegue inmediato.

En el caso de xAI (Grok), la evidencia disponible pone de manifiesto un impacto ambiental significativo asociado a la infraestructura energética empleada. Reportes

sobre el centro de datos Colossus, ubicado en Memphis, indican una operación dependiente de turbinas móviles de gas metano para suplir la elevada demanda energética de un clúster de aproximadamente 100,000 GPUs, lo que incrementa de forma sustancial las emisiones asociadas al funcionamiento del sistema (Hilt, 2025). A diferencia de enfoques basados en centros de datos optimizados y alimentados por redes eléctricas reguladas, este modelo energético ha generado conflictos regulatorios, al operar inicialmente sin permisos completos de calidad del aire, lo que ha despertado preocupaciones en torno a la emisión de óxidos de nitrógeno (NOx) y su potencial impacto en la salud pública local (Streibig, 2026). En conjunto, estos resultados evidencian que la sostenibilidad de la inteligencia artificial no depende únicamente de la eficiencia algorítmica, sino también del tipo de infraestructura energética empleada y del contexto territorial en el que se despliega.

En el caso de Llama 3, los resultados evidencian que el entrenamiento de modelos fundacionales de muy gran escala conlleva un consumo energético extremadamente elevado, asociado al uso simultáneo de decenas de miles de GPUs, así como a infraestructuras de almacenamiento y comunicación de alta capacidad. La literatura técnica señala que, pese a la aplicación de diversas estrategias de paralelismo y optimización, la eficiencia computacional alcanzada implica que una proporción significativa de la energía consumida no se traduce directamente en cálculo efectivo. Asimismo, se destaca que la magnitud del entrenamiento genera picos de demanda eléctrica que ejercen presión sobre la infraestructura energética y térmica de los centros de datos.

Estos hallazgos ponen de manifiesto que la sostenibilidad computacional de los modelos de vanguardia entrenados a gran escala constituye un reto crítico, particularmente en ausencia de reportes detallados y estandarizados sobre emisiones de carbono. Con todo se debe tener en consideración que Llama 3 es un modelo de código abierto, lo que reduce la necesidad de entrenamientos redundantes por parte de terceros y puede generar un ahorro energético neto a nivel global, a pesar de su elevado costo energético inicial (Grattafiori et al., 2024). Por otro lado, el caso de DeepSeek contrasta con la tendencia predominante de la industria hacia el incremento continuo de recursos computacionales. La literatura técnica asociada al modelo DeepSeek-V3 reporta niveles de eficiencia destacados, alcanzados mediante el uso de arquitecturas de Mixture-of-Experts (MoE) y mecanismos de atención latente (MLA) (DeepSeek-AI et al., 2025). Estas estrategias permitieron reducir de forma sustancial las horas de GPU requeridas para el entrenamiento, estimadas en aproximadamente 2.78 millones de horas, frente a las decenas de millones de horas reportadas para modelos comparables, lo que evidencia la posibilidad de

alcanzar un alto rendimiento con una fracción del costo energético habitual (DeepSeek-AI et al., 2025).

En el caso del modelo BLOOM, la literatura revisada presenta un análisis detallado y transparente de su huella de carbono a lo largo del ciclo de vida computacional. Los resultados evidencian que, si bien el entrenamiento de modelos de lenguaje de gran escala implica un consumo energético elevado, una proporción significativa de las emisiones no proviene exclusivamente del cálculo activo, sino también del mantenimiento de la infraestructura y de la fabricación del hardware. Asimismo, se observa que la intensidad de carbono de la red eléctrica utilizada desempeña un papel determinante: gracias al uso de energía de baja intensidad de emisiones principalmente de origen nuclear en la supercomputadora del Fances Jean Zay, la huella total se mantuvo en niveles comparativamente bajos, estimados entre 25 y 50 toneladas de CO₂e (Luccioni et al., 2022). Este hallazgo refuerza la idea de que la sostenibilidad computacional depende tanto del diseño del modelo como del contexto energético operativo.

Tabla 1. Comparación del impacto ambiental y sostenibilidad computacional de modelos de IA

Modelo	Indicadores de Evaluación Ambiental			Análisis
	Impacto energético	Huella de Carbono	Sostenibilidad computacional	Justificación
DeepSeek	Bajo	Baja	Media	Modelo con arquitectura MoE que prioriza eficiencia; reduce drásticamente horas de entrenamiento.
Gemini	Medio	Media	Alta	Eficiencia alta en inferencia (0.24 Wh) y uso de TPUs, mitigado por escala masiva.
BLOOM	Alto	Media	Media	Huella mitigada por red nuclear; destaca por transparencia en ciclo de vida.
Copilot	Alto	Media	Alta	Consumo elevado por complejidad (RAG), compensado por inversión nuclear futura.
ChatGPT	Alto	Alta	Media	Consumo dual intensivo (masividad + entrenamiento); opacidad en métricas exactas.
Llama 3	Alto	Alta	Media	Entrenamiento por fuerza bruta (miles de GPUs); presión sobre infraestructura térmica
xAI (Grok)	Alto	Alta	Media	Dependencia crítica de combustibles fósiles (turbinas de gas) y conflictos locales.

Fuente: Elaboración propia.

A partir de los resultados obtenidos, se evidencia que el impacto ambiental de la inteligencia artificial de gran escala no depende únicamente del tamaño de su infraestructura

computacional, sino también de las metodologías adoptadas para la obtención y gestión de la energía que sustenta los procesos del modelo, las cuales están directamente

condicionadas por las estrategias de cada empresa desarrolladora. En este sentido, el origen de la energía y la forma en que esta es gestionada influyen de manera determinante en la huella ambiental asociada a cada sistema. No obstante, es importante considerar que, independientemente del tipo de fuente energética empleada, la inteligencia artificial genera un impacto ambiental inherente, derivado de la extracción de materiales, la fabricación de equipos y la construcción de la infraestructura necesaria para su operación. Sin embargo, la información recopilada en este estudio se limita principalmente a las etapas posteriores a la implementación de la infraestructura, centrándose en el entrenamiento y el uso operativo de los modelos, debido a la ausencia de datos detallados sobre las fases previas a su concepción y fabricación.

El análisis presentado en la Tabla 1 organiza los modelos de lenguaje evaluados en función de su impacto energético y huella de carbono relativa, ubicando en las primeras posiciones aquellos con menor impacto ambiental estimado. Bajo este criterio, DeepSeek se posiciona como el modelo con menor impacto relativo, lo que constituye uno de los hallazgos más relevantes de la presente investigación. La literatura técnica indica que DeepSeek ha logrado entrenar modelos con un rendimiento comparable a sistemas de la categoría de GPT-4, utilizando aproximadamente el 20% del costo computacional reportado para modelos equivalentes. Este resultado no se atribuye al uso de hardware altamente especializado, sino principalmente a decisiones de diseño arquitectónico, en particular al empleo de arquitecturas de Mixture-of-Experts (MoE) y Multi-Head Latent Attention (MLA), las cuales permiten reducir de forma sustancial el número de parámetros activos, el uso de memoria y el consumo energético durante el entrenamiento.

En este sentido, el caso de DeepSeek sugiere que la sostenibilidad computacional no depende exclusivamente de la disponibilidad de energía limpia, sino también de estrategias algorítmicas orientadas a la eficiencia. El hecho de que arquitecturas como Mixture-of-Experts (MoE) logren reducir drásticamente las horas de entrenamiento sugiere que la industria está transitando de una etapa de "fuerza bruta computacional" representada por Llama 3 y Grok hacia una de "eficiencia algorítmica". Esto implica que la sostenibilidad futura no dependerá solo de energías limpias, sino de innovaciones matemáticas que desacoplen la capacidad de cómputo del consumo energético.

En contraste, Gemini y BLOOM presentan similitudes en cuanto a su contexto operativo y a la transparencia metodológica con la que reportan su impacto ambiental. Ambos modelos evidencian que el uso de redes eléctricas con baja intensidad de carbono, junto con una optimización integral del sistema; que incluye hardware, software e infraestructura, puede contener de manera significativa la huella ambiental, incluso en escenarios de uso masivo. No obstante, en comparación con DeepSeek, sus resultados reflejan menores niveles de eficiencia computacional, lo que se traduce en un impacto energético relativo más elevado dentro de la clasificación presentada. Una comparación relevante puede establecerse entre dos sistemas de inteligencia artificial ampliamente adoptados: ChatGPT y Copilot. Por un lado, ChatGPT, desarrollado por OpenAI, cuenta con una base de usuarios masiva. Si bien la empresa ha implementado optimizaciones en el procesamiento de tokens, la accesibilidad y facilidad de uso de la plataforma han generado un efecto de escalada en la demanda, lo que se traduce en un volumen global de consultas exponencial. Este fenómeno ejerce una presión constante sobre la

infraestructura energética, resultando en un impacto ambiental significativo, mayor en escala que el observado en el caso de Copilot.

Por otro lado, Copilot representa un paradigma distinto, donde el costo energético está asociado a la complejidad del procesamiento. Al operar con enfoques de Generación Aumentada por Recuperación (RAG, por sus siglas en inglés), requiere el análisis integral de documentos completos. Aunque su consumo diario no alcanza el volumen masivo de ChatGPT, la intensidad computacional de este método es considerablemente mayor por tarea, generando una huella de carbono más elevada por operación individual. Esta contrastación sugiere que la evaluación de la huella ambiental de los sistemas de IA no puede limitarse únicamente a las características del modelo, sino que debe incorporar de manera crítica el patrón de uso. Así, se distinguen dos escenarios principales: el impacto por volumen, asociado al consumo masivo de consultas de baja complejidad (ChatGPT), frente al impacto por intensidad, vinculado al procesamiento especializado de datos estructurados (Copilot). El contraste observado entre BLOOM y xAI (Grok) pone de manifiesto que la ubicación geopolítica y el contexto energético constituyen variables determinantes en la sostenibilidad de los modelos de inteligencia artificial. En el caso de BLOOM, el uso de energía de baja intensidad de carbono —principalmente proveniente de centrales nucleares en Francia— junto con una política de transparencia metodológica, permitió contener su huella de carbono y ofrecer estimaciones detalladas de su impacto ambiental.

En contraste, el caso de Grok evidencia un enfoque sustancialmente distinto. Los reportes disponibles indican que el centro de datos Colossus depende del uso intensivo de turbinas

móviles de gas metano para abastecer la elevada demanda energética de un clúster de aproximadamente 100 000 GPUs, en un contexto marcado por conflictos regulatorios y denuncias por contaminación del aire. La utilización de más de treinta turbinas, algunas operando sin los permisos ambientales correspondientes; sugiere un impacto significativo en la huella de carbono, así como riesgos adicionales asociados a la emisión de contaminantes atmosféricos. Este escenario revela una desconexión entre el avance tecnológico y la responsabilidad ambiental, y refuerza la idea de que la sostenibilidad de la inteligencia artificial no depende únicamente de la eficiencia algorítmica, sino también del marco normativo, el contexto territorial y las decisiones energéticas que acompañan su despliegue. La ausencia de regulaciones adecuadas puede amplificar impactos negativos en comunidades locales, particularmente en términos de salud pública y justicia ambiental.

Conclusiones

La inteligencia artificial ha evolucionado desde una disciplina principalmente teórica hasta consolidarse como un motor de transformación estructural en la sociedad contemporánea. Sin embargo, este proceso no ha sido neutral ni lineal, sino que ha estado condicionado por tensiones entre el progreso técnico, las limitaciones de infraestructura y los ciclos de expectativas que han definido sus periodos de expansión y estancamiento a lo largo de su desarrollo histórico. La sostenibilidad computacional emerge como un criterio central e ineludible en la evaluación de los sistemas de inteligencia artificial de gran escala. La evidencia analizada demuestra que el impacto ambiental, expresado en términos de consumo energético y uso de recursos hídricos, varía de forma significativa según la arquitectura del modelo y la matriz energética de los centros de

datos. En este sentido, modelos como DeepSeek evidencian que es posible alcanzar altos niveles de rendimiento mediante estrategias de eficiencia algorítmica, marcando una transición necesaria frente a los enfoques predominantes basados en la fuerza bruta computacional. El impacto social de la inteligencia artificial, particularmente en ámbitos como el mercado laboral y la educación, requiere el desarrollo de marcos de gobernanza proactivos que mitiguen la profundización de las brechas de cualificación y eviten que los procesos de automatización deriven en nuevas formas de precarización. En última instancia, la efectividad de la inteligencia artificial como herramienta de progreso humano dependerá de la capacidad de subordinar su potencia técnica al juicio ético y a la responsabilidad ambiental, promoviendo una transición tecnológica equitativa y sostenible a largo plazo.

Referencias Bibliográficas

- Abeliuk, A., & Gutiérrez, C. (2021). Historia y evolución de la inteligencia artificial. *Bits*. <https://revistasdex.uchile.cl/index.php/bits/article/view/2767>
- Cabra, G. (2024). Inteligencia artificial en salud. *Revista de la Facultad de Ciencias de la Salud Universidad del Cauca*. <https://www.semanticscholar.org/paper/2d1b21071243427c52abb9c9756fca9d03457064>
- DeepSeek-AI, Liu, A., Feng, B., Xue, B., Wang, B., Wu, B., Lu, C., Zhao, C., Deng, C., Zhang, C., Ruan, C., Dai, D., Guo, D., Yang, D., Chen, D., Ji, D., Li, E., Lin, F., Dai, F., & Pan, Z. (2025). DeepSeek-V3 technical report. <https://arxiv.org/pdf/2412.19437v2>
- Díaz, J. (2021). Aprendizaje automático y aprendizaje profundo. *Ingeniare. Revista chilena de ingeniería*, 29(2), 180–181. <https://doi.org/10.4067/S0718-33052021000200180>
- Elsworth, C., Huang, K., Patterson, D., Schneider, I., Sedivy, R., Goodman, S., Townsend, B., Ranganathan, P., Dean, J., Vahdat, A., Gomes, B., & Manyika, J. (2025). Measuring the environmental impact of delivering AI at Google scale. <http://arxiv.org/abs/2508.15734>
- Granados, J., & Baena, L. (2019). Perspectiva histórica y evolución de la inteligencia artificial. En *La inteligencia artificial aplicada a la defensa* (pp. 17-38). <https://dialnet.unirioja.es/servlet/articulo?codigo=6896759>
- Grattafiori, A., Dubey, A., Jauhri, A., Pandey, A., Kadian, A., Al-Dahle, A., Letman, A., Mathur, A., Schelten, A., Vaughan, A., Yang, A., Fan, A., Goyal, A., Hartshorn, A., Yang, A., Mitra, A., Sravankumar, A., Korenev, A., Hinsvark, A., & Ma, Z. (2024). The Llama 3 herd of models. <http://arxiv.org/abs/2407.21783>
- Guachamboza, A., & Baldeón, P. (2024). Inteligencia artificial y su aplicación en la medicina. *Innovarium*. <https://www.semanticscholar.org/paper/ca17ae569d1a0fae39df38f646332ec227f73d0c>
- Hilt, E. (2025). Groups appeal permit for xAI's South Memphis data center. <https://www.selc.org/press-release/groups-appeal-permit-for-xais-south-memphis-data-center-decisions-around-unpermitted-methane-gas-turbines/>
- Kandpal, N., & Raffel, C. (2025). The most expensive part of an LLM should be its training data. <https://doi.org/10.48550/ARXIV.2504.12427>
- León, O., Caraguay, J., & Ruiz, R. (2024). Evolución de la inteligencia artificial y su impacto en la educación: Revisión de la literatura. <https://tsachila.edu.ec/ojs/index.php/TSEDE/article/view/195/129>
- Li, P., Yang, J., Islam, M., & Ren, S. (2025). Making AI less thirsty: The water footprint of AI models. <http://arxiv.org/abs/2304.03271>
- Luccioni, A., Viguier, S., & Ligozat, A. (2022). Estimating the carbon footprint of BLOOM, a 176B parameter language model. *Journal*

- of Machine Learning Research*, 24.
<http://arxiv.org/abs/2211.02001>
- Millán, S. (2025). Inteligencia artificial como herramienta educativa.
<https://www.semanticscholar.org/paper/31c5b48bdf030c2e7b6763bb5078d6920087d714>
- Nakagawa, M., & Smith, B. (2025). Environmental sustainability report. Microsoft. <https://www.microsoft.com/en-us/corporate-responsibility/sustainability/report/>
- Ortiz, M. (2025). Redes neuronales artificiales.
<https://www.semanticscholar.org/paper/b14ecc0189bdc26bdd439c90538e6620535f8ec1>
- Pedraza, J. (2023). La inteligencia artificial en la sociedad: Impacto actual y desafíos futuros. <https://oa.upm.es/75068/>
- Robisco, S. (2024). Historia de la inteligencia artificial.
<https://books.google.com.ec/books?id=U9wxEQAAQBAJ>
- Ruiz, D., & Gastelúa, J. (2025). Inteligencia artificial y sociedad: Mirada desde los estudios sociales de la ciencia y la tecnología. *Holopraxis*.
<https://www.semanticscholar.org/paper/a130835668066bfc2d113f22c458d7b7e8a8dede>
- Sajun, A., Zualkernan, I., & Sankalpa, D. (2024). A historical survey of advances in transformer architectures. *Applied Sciences*, 14(10), 4316.
<https://doi.org/10.3390/APP14104316>
- Sanromán, R. (2025). Sinergia entre la inteligencia artificial y las sociedades.
<https://www.semanticscholar.org/paper/ca17ae569d1a0fae39df38f646332ec227f73d0c>
- Strebig, N. (2026). EPA updates turbine regulations and xAI power options.
<https://www.commercialappeal.com/story/money/business/development/2026/01/15/epa-updated-turbine-regulations-xai-impact-memphis-tn-southaven-ms/88200392007/>
- Thainá, S. (2025). Impacto da inteligência artificial e da automação no mercado de trabalho. *Revista Científica Acertte*.
<https://acertte.org/acertte/article/view/216>
- Villagomez, A. (2025). Impacto de la inteligencia artificial en la sociedad: Revisión sistemática.
<https://www.semanticscholar.org/paper/2d3b7e0327d8cb198e7b8db3042f3aa3bbaf9813>
- Wlach, K. (2019). Are we heading for another AI winter soon? *Forbes*.
<https://www.forbes.com/sites/cognitiveworld/2019/10/20/are-we-heading-for-another-ai-winter-soon/>
- Zaikova, A. (2023). Noviembre de la inteligencia artificial.
<https://www.semanticscholar.org/paper/bc56f32296dc5b61b0dfb9ab8cb3a4c6336185fb>
- Zambrano, F., & Cobeña, T. (2025). Algoritmos energéticamente eficientes en inteligencia artificial y Agenda 2030. *Re-incisol*, 4(8), 3140-3153.
[https://doi.org/10.59282/REINCISOL.V4\(8\)3140-3153](https://doi.org/10.59282/REINCISOL.V4(8)3140-3153)
- t



Esta obra está bajo una licencia de Creative Commons Reconocimiento-No Comercial 4.0 Internacional. Copyright © Exer Stalin Loor Beltrón y Ricardo Orlando Malla Valdiviezo.

