



SOLUCIONES TECNOLÓGICAS CON ENFOQUE GREEN AI

Maribel Aragón García

Instituto Politécnico Nacional, Escuela Superior de Cómputo

maragong@ipn.mx

Num. Orcid: 0000-0002-4478-640X

Adriana Berenice Celis Domínguez

Instituto Politécnico Nacional, Escuela Superior de Cómputo

bcelisd@ipn.mx

Num. Orcid: 0000-0003-4609-9723

Elba Mendoza Macias

Instituto Politécnico Nacional, Escuela Superior de Cómputo

emendozam@ipn.mx

Num. Orcid: 0000-0003-2615-3323

Abstract

The rise of generative Artificial Intelligence in higher education demands evaluation of its environmental cost under digital sustainability guidelines (Green AI). This case study quantifies the energy footprint (Wh), water evaporation (mL), and carbon equivalent emissions (gCO₂e) of prompt engineering interactions with large language models (LLMs) carried out by 16 undergraduate Data Science students across four teams during a 90-minute Challenge-Based Learning session. A mixed-method concurrent design was applied. Results reveal a key operational paradox: the team with the shortest server interaction (1.6 Wh, 0.8 g CO₂e) tripled its total ecosystem energy footprint (4.8 Wh) due to simultaneous use of three networked devices. Green AI efficiency in educational settings depends not solely on query brevity, but on collective management of local hardware infrastructure.

Palabras clave: Green AI, Sostenibilidad digital, Modelos de Lenguaje Grande (LLM), Huella ambiental, Aprendizaje Basado en Retos (ABR)

La adopción masiva de la Inteligencia Artificial Generativa (IAGen) y los modelos de lenguaje grande (LLM) ha transformado irreversiblemente la educación superior al abrir nuevos horizontes para la co-creación de conocimiento en el aula. No obstante, esta transición pedagógica digitalizada conlleva un costo ecológico crítico e invisibilizado. Schwartz et al. (2020) advierten que el desarrollo de la IA ha priorizado la precisión algorítmica y el

tamaño de los modelos por encima de la eficiencia computacional, configurando el paradigma de Red AI, donde el gasto energético crece exponencialmente. Aunque históricamente la preocupación se centró en la fase de entrenamiento, las investigaciones fundamentales de Strubell et al. (2019) y los reportes posteriores de Patterson et al. (2021) han demostrado de manera empírica que el consumo energético agregado de la fase de inferencia termina superando drásticamente al del



entrenamiento a lo largo de la vida útil del sistema, debido al volumen masivo de peticiones globales diarias. Este consumo se traduce en dos vectores principales de degradación ambiental. Por un lado, Luccioni et al. (2023) destacan en Power Hungry Processing que la intensidad de las emisiones de carbono por consulta depende estrictamente del tamaño del modelo, la longitud del texto generado y la matriz eléctrica regional de los centros de datos que alimentan el hardware. Por otro lado, Ren et al. (2023), en Making AI Less Thirsty, cuantificaron que incluso el procesamiento de interacciones de texto breves demanda una cantidad considerable de agua evaporada localmente para los sistemas de enfriamiento térmico de los servidores. Frente a esta crisis ecosistémica surge la Inteligencia Artificial Sostenible o Green AI, definida por Schwartz et al. (2020) como una directriz metodológica y ética que considera la eficiencia y el costo ambiental como variables de éxito primordiales. A pesar de la importancia de este enfoque, existe un vacío de conocimiento sustancial en el contexto educativo sobre cómo las dinámicas de co-creación y aprendizaje en el aula se alinean o contraponen con los principios de Green AI. Aunque el impacto individual de un solo prompt es numéricamente pequeño, la proliferación masiva de estas metodologías a escala universitaria exige examinar empíricamente la huella ecológica de estos procesos. A partir de este escenario, se plantea la interrogante científica sobre cuál es el impacto de la huella ambiental, medida en consumo energético (Wh), evaporación hídrica (mL) y emisiones de CO_{2e}, derivado de las interacciones de prompt engineering sostenidas simultáneamente por equipos de estudiantes de educación superior al diseñar soluciones tecnológicas alineadas con los Objetivos de Desarrollo Sostenible (ODS) bajo un enfoque de Green AI. Para responder a esto, el objetivo de investigación consiste en auditar cuantitativamente el impacto ambiental de las interacciones discursivas con LLMs realizadas por estudiantes universitarios de Ciencia de Datos durante un reto de co-creación tecnológica basado en los ODS, contrastando críticamente el beneficio

pedagógico de la solución diseñada frente al costo ecológico de su ejecución computacional.

Metodología

El diseño metodológico de la investigación se inscribió bajo un enfoque mixto (cualitativo-cuantitativo), adoptando un diseño pragmático de tipo concurrente y transaccional con un alcance descriptivo-explicativo. Conforme a Hernández-Sampieri y Mendoza (2018), su naturaleza concurrente radica en la recolección simultánea y equitativa de las narrativas cualitativas del aprendizaje junto con las métricas cuantitativas del consumo de la infraestructura tecnológica, facilitando una triangulación de datos inmediata; asimismo, posee un criterio transaccional debido a que la auditoría de los indicadores se limitó a un único momento temporal coincidente con el reto áulico (Hernández-Sampieri y Mendoza, 2018). Desde la perspectiva pedagógica, la estrategia se basó en el Aprendizaje Basado en Retos (ABR) y se ejecutó en el semestre 2025-2026-2 dentro de una institución pública de educación superior, con una muestra no probabilística por conveniencia de 16 universitarios de entre 21 y 23 años que cursaban el octavo semestre de la Licenciatura en Ciencia de Datos y contaban con conocimientos previos en criterios ambientales, sociales y de gobernanza (ESG), organizándose en cuatro equipos independientes. La intervención se desarrolló en una única sesión intensiva de 90 minutos dividida en cuatro fases secuenciales del ciclo ABR: la primera de encuadre y contextualización, la segunda de investigación autónoma, la tercera de co-creación y diseño del reto por equipos, y la cuarta de presentación y recolección de indicadores. Para el procesamiento de la información se utilizó el modelo Claude (Anthropic) como motor analítico encargado de extraer, estructurar y normalizar los datos de las interacciones, tales como la longitud de caracteres, el volumen de tokens generados de entrada y salida, y la frecuencia de iteraciones. Con el fin de validar científicamente la conversión de estos datos en métricas de impacto ambiental, se emplearon los modelos matemáticos y factores de



emisión estandarizados por Schwartz et al. (2020) para la fundamentación de Green AI, complementados con los criterios de consumo hídrico y energético planteados por Dodge et al. (2022) y Luccioni et al. (2023). De este modo, el procedimiento analítico cuantitativo se rigió mediante la ecuación adaptada para la auditoría de interacciones generativas distribuidas

$$HE (Wh) = \sum_i [(Tin_i \cdot Ein + Tout_i \cdot Eout) \cdot Dk \cdot PFD]$$

Donde Tin_i y $Tout_i$ son los tokens de entrada y salida por intercambio i ; Ein y $Eout$ son los coeficientes de energía por token del LLM utilizado, Dk es la constante de penalización por el número de dispositivos físicos conectados en red por equipo, y PFD es la efectividad del uso de energía estimada para la nube regional. Finalmente, los vatios-hora (Wh) resultantes se multiplicaron por la intensidad de carbono de la red eléctrica local para obtener los gramos de gCO_2e netos liberados, en tanto que el estrés hídrico se cuantificó en mililitros de agua de enfriamiento evaporada por unidad de cómputo.

Resultados

El análisis de contenido automatizado con Claude permitió clasificar las bitácoras de los estudiantes de Ciencia de Datos, quienes demostraron asimilar los criterios ESG y el enfoque *Green AI*. Los Equipos 1, 2 y 3 convergieron autónomamente en modelos tabulares tradicionales (*Random Forest* y *Decision Trees*), justificando técnicamente el uso de estructuras de bajo costo computacional y alta interpretabilidad para reducir la huella de carbono al prescindir de GPU. En contraste, el Equipo 4 optó por un LLM preentrenado que, aunque optimizó la personalización, introdujo una arquitectura de caja negra con mayor huella ambiental por su dependencia de aceleradores de hardware.

Para la estimación paramétrica, la extensión de las respuestas (600 a 900 palabras) se transformó a tokens mediante los coeficientes energéticos de Luccioni et al. (2023) y los factores de intensidad en la nube de Dodge et al. (2022). Los resultados

confirmaron una correlación lineal directa entre el consumo del servidor y la extensión transaccional de la conversación. Así, el Equipo 3 (ODS 11) registró la huella directa más alta de la categoría tabular con 4.0 Wh, 15 mL de agua de estrés hídrico y 2.0 g de CO_2e . Le siguió el Equipo 1 con 3.6 Wh, 13.5 mL y 1.8 g de CO_2e tras un intercambio de 10,800 tokens, mientras que el Equipo 2, al limitar su interacción a 6 respuestas, mitigó su impacto a 2.4 Wh de energía y 1.2 g de carbono.

Tabla 1. Impacto ambiental de las interacciones de inferencia por equipo

Equipo	Resp.	Tokens acumulados	Energía (Wh)	Agua (mL)	Carbono (gCO_2e)	E. total*	GPU
1	9	10,800	3.6	13.5	1.8	3.6	No
2	6	7,200	2.4	9.0	1.2	2.4	No
3	10	12,000	4.0	15.0	2.0	4.0	Opcional
4	4	4,800	1.6	6.0	0.8	4.8	Sí

Nota. E. total* = energía total del ecosistema local, ajustada por Dk (penalización de dispositivos en red). ⚠ El Equipo 4 registró 1.6 Wh en el servidor (menor de todos), pero 4.8 Wh en el ecosistema local por operar con $Dk = 3$ dispositivos sincrónicos. Resp. = número de respuestas. gCO_2e = gramos de dióxido de carbono equivalente.

El Equipo 4 (ODS 4) exhibió un comportamiento transaccional inversamente proporcional a su impacto en el entorno local. Aunque registró el consumo directo más bajo en los servidores remotos (1.6 Wh, 6.0 mL y 0.8 g de CO_2e), la integración de la variable Dk (penalización por hardware, tres dispositivos físicos conectados en red sincrónicamente) modificó significativamente la huella global, elevando la energía total del ecosistema áulico de ese nodo a 4.8 Wh (superando incluso al Equipo 3). Este hallazgo evidencia que la optimización áulica bajo directrices de *Green AI* no depende únicamente de la brevedad de la consulta con el LLM, sino de la gestión de la infraestructura física distribuida empleada por los estudiantes.



Al normalizar los indicadores por número de respuestas, se observó un valor constante de 0.4 Wh, 1.5 mL y 0.2 g de CO_2e por cada intercambio conversacional en los cuatro equipos, con independencia del modelo de aprendizaje automático propuesto o de su nivel de interpretabilidad. Esta constancia per cápita confirma que el patrón de consumo es uniforme a nivel de inferencia individual, y que la diferencia en la huella total entre equipos se explica exclusivamente por el volumen transaccional acumulado.

Conclusiones

La intervención didáctica con modelos de lenguaje grande (LLM) evidencia que las dinámicas pedagógicas y el costo material computacional son interdependientes en el marco de la *Green AI*. Los consumos de los Equipos 1, 2 y 3 (2.4 a 4.0 Wh) aportan evidencia empírica a microescala áulica que respalda a Strubell et al. (2019) y Patterson et al. (2021) sobre el significativo impacto ecológico de la fase de inferencia. En alineación con Luccioni et al. (2023), la diferencia transaccional entre el Equipo 3 (12,000 tokens) y el Equipo 2 (7,200 tokens) confirma que la longitud y frecuencia de las consultas determinan la intensidad energética y las emisiones, que variaron de 1.2 g a 2.0 g de CO_2e .

El hallazgo más disruptivo provino del Equipo 4: aunque su interacción en el centro de datos remoto representaba la huella más baja (1.6 Wh, 6.0 mL de agua, 0.8 g de CO_2e) según los criterios de Luccioni et al. (2023) y Ren et al. (2023), la inclusión de la variable de hardware local (*Dk* por tres dispositivos) triplicó su huella neta a 4.8 Wh, lo que contradice la idea intuitiva de que la concisión textual es siempre la opción más ecoeficiente.

Esto demuestra que la falta de gestión colectiva de la infraestructura presencial anula la optimización digital, lo que complementa el marco de Schwartz et al. (2020) al exigir que la sostenibilidad educativa integre tanto la eficiencia en la nube como la arquitectura física local.

Bajo el enfoque pedagógico del Aprendizaje Basado en Retos (ABR), la elección autónoma de los Equipos 1, 2 y 3 de emplear modelos tabulares de bajo costo justifica que la co-creación orientada por principios de *Green AI* es eficaz para desarrollar una ciudadanía digital ética capaz de equilibrar el beneficio metodológico y la responsabilidad ambiental.

Referencias

- Dodge, J., Taylor, S., Borchardt, R., Ostyakova, G., Walters, N., Sanh, V., ... & Roy, D. (2022). Measuring the carbon intensity of AI in cloud instances. En *Proceedings of the 2022 ACM Conference on Fairness, Accountability, and Transparency* (pp. 1877–1894). <https://doi.org/10.1145/3531146.3533234>
- Hernández-Sampieri, R., & Mendoza, C. (2018). *Metodología de la investigación: las rutas cuantitativa, cualitativa y mixta*. McGraw-Hill Education.
- Li, P., Yang, J., Jiang, M. A., Wei, L., & Ren, S. (2023). Making AI less “thirsty”: Uncovering and addressing the secret water footprint of large language models. *arXiv preprint arXiv:2304.03271*.
- Luccioni, A. S., Jernite, Y., & Strubell, E. (2023). Power hungry processing: Watts driving the cost of AI deployment? *arXiv preprint arXiv:2311.16863*.
- Luccioni, A. S., Viguier, S., & Ligozat, A.-L. (2023). Estimating the carbon footprint of BLOOM, a 176B parameter language model. *Journal of Machine Learning Research*, 24(253), 1–15.
- Patterson, D., Gonzalez, J., Le, Q., Liang, C., Munguia, L. M., Rothchild, D., ... & Dean, J. (2021). Carbon emissions and large neural network training. *arXiv preprint arXiv:2104.10350*.
- Schwartz, R., Dodge, J., Smith, N. A., & Etzioni, O. (2020). Green AI. *Communications of the ACM*, 63(12), 54–63. <https://doi.org/10.1145/3381831>
- Strubell, E., Ganesh, A., & McCallum, A. (2019). Energy and policy considerations for deep learning in NLP. En *Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics* (pp. 3645–3650).
- U.S. Energy Information Administration (EIA). (2024). *State Carbon Dioxide Emissions Data*. Department of Energy.