

## **REVISÃO SISTEMÁTICA SOBRE IMPACTOS AMBIENTAIS DE INFRAESTRUTURAS E APLICAÇÕES DE INTELIGÊNCIA ARTIFICIAL**

**HELENA FARIAS RIBEIRO**

UNIVERSIDADE FEDERAL DE UBERLÂNDIA

**CAROLINA COELHO DA SILVEIRA**

PROGRAMA DE PÓS-GRADUAÇÃO EM ADMINISTRAÇÃO

**CARLA BONATO MARCOLIN**

UNIVERSIDADE FEDERAL DE UBERLÂNDIA

**CARLOS HENRIQUE RODRIGUES**

UNB UNIVERSIDADE DE BRASÍLIA

**MIRIAM TAKIMURA**

UNIVERSIDADE FEDERAL DE UBERLÂNDIA

### **Introdução**

A expansão da Inteligência Artificial Generativa (IAG) impulsiona data centers especializados, suscitando preocupações ambientais. Os data centers de IAG demandam recursos energéticos superiores, atingindo dezenas de terawatts-hora anualmente e emissões de gigatoneladas de CO<sub>2</sub> (Brevini, 2020; Sidorkin, 2025). No Brasil, a expansão ocorre sem avaliação ambiental adequada, reproduzindo padrões onde territórios periféricos fornecem recursos enquanto o controle tecnológico permanece centralizado (Teles, 2025).

### **Problema de Pesquisa e Objetivo**

Este estudo busca responder: o que as pesquisas acadêmicas informam sobre os impactos ambientais gerados por infraestruturas de IA? Desse modo, o objetivo é sintetizar o conhecimento científico sobre esses impactos, proporcionando base para estratégias de mitigação que considerem as especificidades do Sul Global.

### **Fundamentação Teórica**

Por ser uma revisão sistemática da literatura, este trabalho não conta com uma seção específica de fundamentação teórica.

### **Metodologia**

Este estudo emprega metodologia mista com análise bibliométrica quantitativa, utilizando o bibliometrix, e revisão sistemática qualitativa, utilizando o método PRISMA. A busca inicial identificou 118 artigos e, após a aplicação dos critérios de inclusão/exclusão, 34 artigos foram selecionados para análise.

### **Análise e Discussão dos Resultados**

A produção científica concentra-se no Norte Global, evidenciando sub-representação do Sul Global. A análise identificou nove categorias principais: quantificação energética, otimização, gestão térmica, frameworks de sustentabilidade, metodologias de avaliação, gestão de recursos, contextos geográficos, aplicações setoriais e aspectos regulatórios, revelando impactos mensuráveis e estratégias de mitigação viáveis.

### **Considerações Finais**

A revisão identificou impactos ambientais significativos (GPT-3: 1.287 MWh, 552 toneladas CO<sub>2</sub>) e estratégias de mitigação promissoras (reduções até 80% via aprendizado federado). Evidenciou-se concentração de produção científica no Norte Global versus sub-representação do Sul Global.

### **Referências**

Brevini, B. (2020). Black boxes, not green: Mythologizing artificial intelligence and omitting the environment. *Big Data & Society*, 7(2), 2053951720935141. <https://doi.org/10.1177/2053951720935141> Sidorkin, A. (2025). Environmental Impact of Generative AI: Carbon and Water Footprint. *AI-EDU Arxiv*. <https://doi.org/10.36851/ai-edu.vi.5448> Teles, G. (2025). Como data centers repetem a lógica colonial digital no Brasil. *Intercept Brasil*. <https://www.intercept.com.br/2025/07/25/como-data-centers-repetem-a-logica-colonial-digital-no-brasil/>

### **Palavras Chave**

Inteligência Artificial, Data Center, Impacto Ambiental

### **Agradecimento a órgão de fomento**

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001 e do Conselho Nacional de Desenvolvimento Científico e Tecnológico - Brasil (CNPq).

# REVISÃO SISTEMÁTICA SOBRE IMPACTOS AMBIENTAIS DE INFRAESTRUTURAS E APLICAÇÕES DE INTELIGÊNCIA ARTIFICIAL

## 1 INTRODUÇÃO

A expansão da Inteligência Artificial Generativa (IAG) impulsiona data centers especializados, suscitando preocupações ambientais. Os data centers de IAG demandam recursos energéticos superiores, atingindo dezenas de terawatts-hora anualmente e emissões de gigatoneladas de CO<sub>2</sub> (Brevini, 2020; Sidorkin, 2025). A pegada hídrica intensifica a competição por recursos aquíferos (Hiremath, 2024; Sidorkin, 2025) enquanto resíduos eletrônicos concentram-se no Sul Global (Brevini, 2020).

No Brasil, a expansão ocorre sem avaliação ambiental adequada, reproduzindo padrões onde territórios periféricos fornecem recursos enquanto o controle tecnológico permanece centralizado (Teles, 2025).

Este estudo busca responder: o que as pesquisas acadêmicas informam sobre os impactos ambientais gerados por infraestruturas de IA? Desse modo, o objetivo é sintetizar o conhecimento científico sobre esses impactos, proporcionando base para estratégias de mitigação que considerem as especificidades do Sul Global.

## 2 METODOLOGIA

Este estudo emprega metodologia mista com análise bibliométrica quantitativa e revisão sistemática qualitativa, baseado em Bota-Avram (2023) e Lyu, Liu e Yao (2023).

A coleta foi realizada nas bases Scopus e Web of Science, selecionadas por sua qualidade acadêmica (Zhu & Liu, 2020) e compatibilidade com o software Bibliometrix. Utilizou-se estrutura PICO (População, Intervenção, Comparação, Resultado) para orientar o processo (Grover & Naskar, 2024) com protocolo registrado em <https://osf.io/> (Rao, 2023).

### Quadro 1

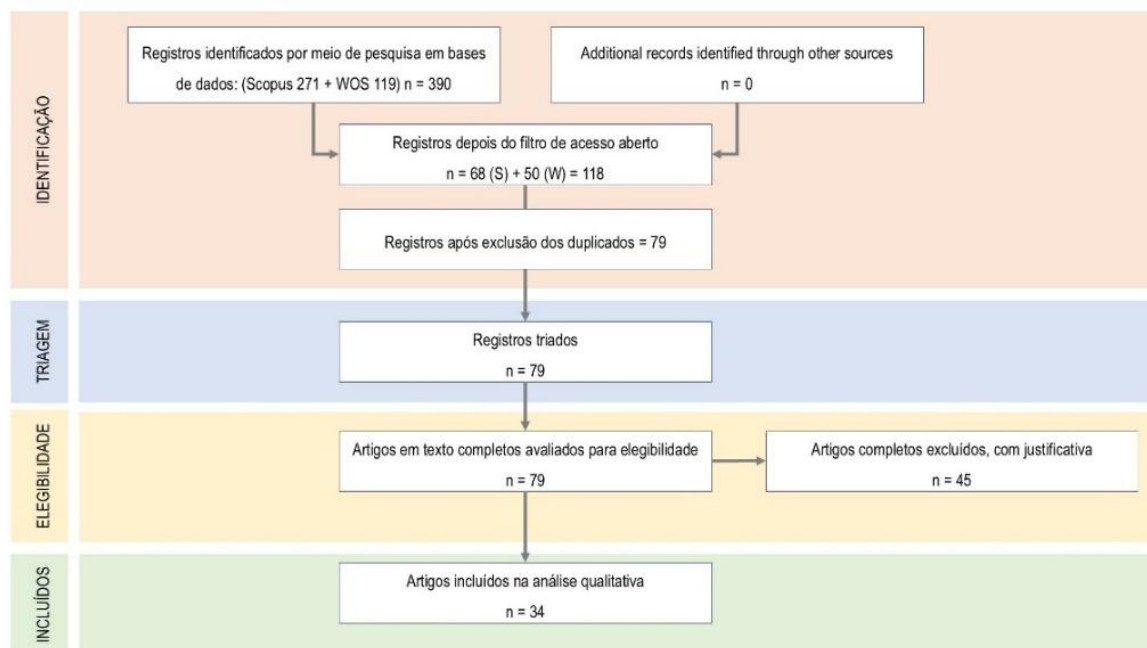
#### PICO

Categoria	Descrição
<b>P</b> (População/Problema)	Infraestruturas computacionais que processam cargas de trabalho de IA incluindo: data centers híbridos, centros de processamento ML/DL, infraestruturas cloud com aplicações IA, e sistemas distribuídos para IA.
<b>I</b> (Intervenção)	Operações computacionais relacionadas à IA incluindo: processamento de modelos ML/DL, operações de data centers que hospedam aplicações IA, sistemas de resfriamento e energia para cargas de trabalho intensivas.
<b>C</b> (Comparação)	Comparações entre tecnologias, configurações, períodos temporais, métricas de eficiência, ou análises de cenários únicos com contribuição relevante.
<b>O</b> (Outcomes/Resultados)	Evidências sobre impactos ambientais incluindo: dados quantitativos ou qualitativos sobre energia, carbono, água, resíduos; análises de tendências; projeções fundamentadas; ou contribuições metodológicas para medição de impactos.

Nota. Elaborado pelos autores (2025).

As palavras-chave definidas para busca nas bases de dados foram: ("data centers" OR "data centres" OR "server farms" OR "computing facilities" OR "server facilities" OR "cloud facilities" OR "datacenter" OR "datacentre" OR "computing centers" OR "IT facilities" OR "server infrastructure" OR "cloud infrastructure") AND ("environmental impact" OR "environmental effects" OR "ecological impact" OR "carbon footprint" OR "greenhouse gas emissions" OR "energy consumption" OR "environmental sustainability" OR "ecological footprint" OR "climate impact" OR "carbon emissions" OR "sustainability" OR "green computing") AND ("artificial intelligence").

Figura 1  
Fluxograma de coleta de dados (PRISMA)



A configuração específica utilizada para a coleta de dados encontra-se detalhada na Figura 1, estruturada de acordo com o método PRISMA (Arvanitis, 2024).

A busca identificou 118 artigos de acesso aberto (68 na Scopus e 50 na Web of Science). Após exclusão de 39 duplicados e 17 inacessíveis, 62 estudos passaram por análise qualitativa. Aplicando-se os critérios de inclusão/exclusão, eliminaram-se 28 estudos, resultando em 34 artigos para análise bibliométrica e revisão sistemática, processados via Bibliometrix (Aria & Cuccurullo, 2017) seguindo diretrizes PRISMA (Arvanitis, 2024).

### 3 RESULTADOS

A seção a seguir apresenta os resultados da análise bibliométrica e da análise qualitativa, referente a revisão sistemática da literatura dos 34 estudos selecionados, os quais serão analisados a fim de atender o seguinte objetivo de identificar e sintetizar o conhecimento científico sobre os impactos ambientais gerados por infraestruturas e aplicações de IA.

#### 3.1 Análise Bibliométrica

A produção científica por país (Figura 2) concentra-se na China (51), Estados Unidos (18), Arábia Saudita (11) e Grã-Bretanha (8). Esta distribuição evidencia predominância do Norte Global na produção de conhecimento sobre impactos ambientais de IA.

A Figura 3 apresenta o mapa temático da análise de bigramas dos resumos dos estudos incluídos na revisão sistemática. Os bigramas correspondem a pares consecutivos de palavras que auxiliam na compreensão e modelagem de tarefas linguísticas. A análise de bigramas identifica padrões textuais mediante o exame da ocorrência de pares adjacentes de palavras (Chakraborty & Sarma, 2024). O eixo vertical representa o grau de desenvolvimento temático (densidade) e o eixo horizontal indica o grau de relevância (centralidade). O tamanho de cada cluster corresponde à quantidade de bigramas que contém.

O cluster "artificial intelligence" emerge como mais robusto (45 bigramas, 230 ocorrências), seguido por "renewable energy" (19 bigramas, 46 ocorrências).


Os clusters "artificial intelligence", "renewable energy" e "data centres" posicionam-se como *motor themes*, indicando temas centrais consolidados. O cluster "environmental impact"

apresenta centralidade média, enquanto "environmental sustainability", "greenhouse gas" e "energy storage" caracterizam-se como temas emergentes ou em declínio.

*Figura 2*  
*Produção científica por países*



*Figura 3*  
*Mapa temático*



### 3.2 Análise Qualitativa

A análise qualitativa dos 34 estudos identificou nove categorias principais de investigação sobre impactos ambientais de infraestruturas de IA.

- **Quantificação de Consumo Energético:** Os estudos documentam impactos quantitativos consideráveis. Moravec et al. (2025) demonstram que GPT-3 consome 1.287 MWh durante treinamento, gerando 552 toneladas de CO<sub>2</sub> equivalente, enquanto ChatGPT processa 200 milhões de solicitações diárias consumindo mais de 500 MWh. Latif et al. (2024) registraram demanda máxima de 8,4 kW em sistema de 8 GPUs NVIDIA H100, demonstrando reduções de até 75% no consumo através de otimização de *batch size*.
- **Estratégias de Otimização Energética:** Barbieri et al. (2025) documentaram economias superiores a 80% mediante compressão de modelos em aprendizado federado. Ajagekar e You (2024) demonstraram reduções de 9,8% nas emissões e 12,5% no consumo energético através de aprendizado quântico variacional. Yang et al. (2019) propuseram *frameworks* de data center verde integrando controle inteligente e refrigeração otimizada.
- **Gestão Térmica:** Geng et al. (2024) desenvolveram o sistema TESLA para controle otimizado de resfriamento, enquanto Huang et al. (2023) implementaram geminação de temperatura baseada em IA. Shen e Zheng (2025) propuseram aproveitamento de calor residual para aquecimento urbano.
- **Frameworks de Sustentabilidade:** Cao et al. (2022) estabeleceram *roadmap* para neutralidade de carbono baseado em energia renovável, eficiência energética e reciclagem. Tabbakh et al. (2024) desenvolveram framework para IA Verde integrando otimização de modelos e hardware eficiente.
- **Metodologias de Avaliação:** Berthelot et al. (2024) desenvolveram metodologia baseada em Avaliação do Ciclo de Vida para IA generativa. Rappaport et al. (2024) introduziram o “fator de desperdício” como métrica de eficiência energética.
- **Gestão de Recursos:** Liu et al. (2024) investigaram transferência de cargas computacionais para otimização energética. Qu et al. (2024) desenvolveram despacho energético distribuído integrando *data centers* com captura de carbono.
- **Contextos Geográficos:** Pomnar et al. (2023) analisaram previsão energética em *data centers* de hiperescala na Índia. Effoduh (2024) investigou desafios de pobreza energética no contexto africano frente à expansão da IA.
- **Aplicações Setoriais:** Doo et al. (2024) examinaram IA na radiologia, demonstrando que otimizações diagnósticas aumentam simultaneamente emissões de gases de efeito estufa. Ma et al. (2025) desenvolveram planejamento preditivo para resfriamento líquido alcançando alta precisão (Erro Quadrático Médio: 1,349; Raiz do Erro Quadrático Médio: 1,157).
- **Aspectos Regulatórios:** Echeverría (2025) investigou integração de sustentabilidade na legislação de dados da União Europeia, propondo uma governança eco cêntrica. Newkirk et al. (2024) identificaram barreiras práticas que impedem adoção de eficiência energética mesmo quando tecnicamente viável.

#### 4 CONCLUSÃO

A revisão identificou impactos mensuráveis e estratégias de mitigação viáveis assim como a concentração no Norte Global versus sub-representação do Sul Global, contrastando com "zonas de sacrifício ambiental" onde custos recaem sobre comunidades vulnerabilizadas (Teles, 2025).

Recomenda-se priorizar pesquisas sobre contextos do Sul Global para desenvolver estratégias adequadas às especificidades territoriais.

#### REFERÊNCIAS

- Ajagekar, A., & You, F. (2024). Variational quantum circuit learning-enabled robust optimization for AI data center energy control and decarbonization. *Advances in Applied Energy*, 14, 100179. <https://doi.org/10.1016/j.adapen.2024.100179>
- Aria, M., & Cuccurullo, C. (2017). bibliometrix: An R-tool for comprehensive science mapping analysis. *Journal of Informetrics*, 11(4), 959–975. <https://doi.org/10.1016/j.joi.2017.08.007>
- Arvanitis, C. D. (2024). Systematic literature review in five steps. *The Journal of the Acoustical Society of America*, 155. <https://doi.org/10.1121/10.0026958>
- Barbieri, L., Kianoush, S., Nicoli, M., Serio, L., & Savazzi, S. (2025). A close look at the communication efficiency and the energy footprints of robust federated learning in industrial IoT. *IEEE Internet of Things Journal*, 12(11), 15130–15150. <https://doi.org/10.1109/JIOT.2025.3530265>
- Berthelot, A., Caron, E., Jay, M., & Lefèvre, L. (2024). Estimating the environmental impact of Generative-AI services using an LCA-based methodology. *Procedia CIRP*, 122, 707–712. <http://dx.doi.org/10.1016/j.procir.2024.01.098>
- Bota-Avram, C. (2023). Bibliometrics research methodology. In *Science Mapping of Digital Transformation in Business* (pp. 9-13). Springer, Cham. [https://doi.org/10.1007/978-3-031-26765-9\\_2](https://doi.org/10.1007/978-3-031-26765-9_2)
- Brevini, B. (2020). Black boxes, not green: Mythologizing artificial intelligence and omitting the environment. *Big Data & Society*, 7(2), 2053951720935141. <https://doi.org/10.1177/2053951720935141>
- Cao, Z., Zhou, X., Hu, H., Wang, Z., & Wen, Y. (2022). Toward a systematic survey for carbon neutral data centers. *IEEE Communications Surveys & Tutorials*, 24(2), 895-936. <https://doi.org/10.1109/comst.2022.3161275>
- Chakraborty, R., & Sarma, S. K. (2024). N-Gram based Assamese Question Pattern Extraction and Probabilistic Modelling. *Journal of Electrical Systems*, 20(3), 712-726. <http://dx.doi.org/10.52783/jes.2996>
- Doo, F. X., Vossenrich, J., Cook, T. S., Moy, L., Almeida, E. P., Woolen, S. A., ... & Hanneman, K. (2024). Environmental sustainability and AI in radiology: a double-edged sword. *Radiology*, 310(2), e232030. <https://doi.org/10.1148/radiol.232030>
- Echeverría, E. S. (2025). Integrating environmental sustainability into EU data law and governance: The case of health data. *Review of European, Comparative & International Environmental Law*, 34(2), 512-521. <https://doi.org/10.1111/reel.12614>
- Effoduh, J. O. (2024). Africa's energy poverty in an artificial intelligence (AI) world: Struggle for Sustainable Development Goal 7. *Journal of Sustainable Development Law and Policy*, 15(3), 32–63. <https://doi.org/10.4314/jsdlp.v15i3.2>
- Geng, H., Sun, Y., Li, Y., Leng, J., Zhu, X., Zhan, X., ... & Liu, Y. (2024). TESLA: Thermally Safe, Load-Aware, and Energy-Efficient Cooling Control System for Data Centers. In *Proc. of the 53rd International Conference on Parallel Processing* (pp. 939-949).
- Grover, S., & Naskar, C. (2024). How to Write a Systematic Review with Meta-analysis? *International Journal of Advanced Medical & Health Research*, 11(2), 132-139. [https://doi.org/10.4103/ijamr.ijamr\\_263\\_24](https://doi.org/10.4103/ijamr.ijamr_263_24)
- Hiremath, R. B. (2024). AI-Embedded Data Centres: Promoting Sustainability and Reducing Water Footprint. In *2024 First International Conference on Data, Computation and Communication (ICDCC)* (pp. 40-44). IEEE. <http://dx.doi.org/10.1109/ICDCC62744.2024.10961316>
- Huang, N., Li, X., Xu, Q., Chen, R., Chen, H., & Chen, A. (2023). Artificial intelligence-based temperature twinning and pre-control for data center airflow organization. *Energies*, 16(16), 6063. <https://doi.org/10.3390/en16166063>

- Latif, I., Newkirk, A. C., Carbone, M. R., Munir, A., Lin, Y., Koomey, J., ... & Dong, Z. (2025). Single-Node Power Demand During AI Training: Measurements on an 8-GPU NVIDIA H100 System. *IEEE Access*, 13, 61740-61747. <https://doi.org/10.1109/ACCESS.2025.3554728>
- Liu, L., Shen, X., Chen, Z., Sun, Q., & Wennersten, R. (2024). Optimal energy management of data center micro-grid considering computing workloads shift. *IEEE Access*, 12, 102061-102075. <http://dx.doi.org/10.1109/ACCESS.2024.3432120>
- Lyu, P., Liu, X., & Yao, T. (2023). A bibliometric analysis of literature on bibliometrics in recent half-century. *Journal of Information Science*. <https://doi.org/10.1177/01655515231191233>
- Ma, S., Liu, Y., Liu, Y., Wang, J., Fang, Q., & Huang, Y. (2025). Artificial intelligence-enabled predictive energy saving planning of liquid cooling system for data centers. *Advanced Engineering Informatics*, 65, 103283. <https://doi.org/10.1016/j.aei.2025.103283>
- Moravec, V., Gavurova, B., & Kovac, V. (2025). Environmental footprint of GenAI—Changing technological future or planet climate?. *Journal of Innovation & Knowledge*, 10(3), 100691. <http://dx.doi.org/10.1016/j.jik.2025.100691>
- Newkirk, A. C., Hanus, N., & Payne, C. T. (2024). Expert and operator perspectives on barriers to energy efficiency in data centers. *Energy Efficiency*, 17(6), 63. <https://doi.org/10.1007/s12053-024-10244-7>
- Pomnar, A., Rajawat, A. S., Tatkar, N. S., & Bhaladhare, P. (2023). Sustainable Power Prediction and Demand for Hyperscale Datacenters in India. *Engineering Proceedings*, 59(1), 124. <https://doi.org/10.3390/engproc2023059124>
- Qu, Q., Teng, F., Xu, Q., & Li, Y. (2024). Distributed Energy Dispatch for Geo-Data Centers Port Microgrid. *Journal of Marine Science and Engineering*, 12(6), 916. <https://doi.org/10.3390/jmse12060916>
- Rao, S. (2023). An Introduction to Systematic Reviews and Meta-Analyses. *APIK Journal of Internal Medicine*, 11(3), 141-146. [https://doi.org/10.4103/ajim.ajim\\_36\\_23](https://doi.org/10.4103/ajim.ajim_36_23)
- Rappaport, T. S., Ying, M., Piovesan, N., De Domenico, A., & Shakya, D. (2024). Waste factor and waste figure: A unified theory for modeling and analyzing wasted power in radio access networks for improved sustainability. *arXiv preprint arXiv:2405.07710v2*. <https://doi.org/10.48550/arXiv.2405.07710>
- Shen, R., & Zheng, R. (2024). An improved control method of district heating system based on waste heat utilization in data center. In *Journal of Physics: Conference Series* (Vol. 2975, No. 1, p. 012004). IOP Publishing. <http://dx.doi.org/10.1088/1742-6596/2975/1/012004>
- Sidorkin, A. (2025). Environmental Impact of Generative AI: Carbon and Water Footprint. *AI-EDU Arxiv*. <https://doi.org/10.36851/ai-edu.vi.5448>
- Tabbakh, A., Al Amin, L., Islam, M., Mahmud, G. I., Chowdhury, I. K., & Mukta, M. S. H. (2024). Towards sustainable AI: a comprehensive framework for Green AI. *Discover Sustainability*, 5(1), 408. <https://doi.org/10.1007/s43621-024-00641-4>
- Teles, G. (2025). Como data centers repetem a lógica colonial digital no Brasil. *Intercept Brasil*. <https://www.intercept.com.br/2025/07/25/como-data-centers-repetem-a-logica-colonial-digital-no-brasil/>
- Yang, J., Xiao, W., Jiang, C., Hossain, M. S., Muhammad, G., & Amin, S. U. (2019). Ai-powered green cloud and data center. *IEEE Access*, 7, 4195-4203. <http://dx.doi.org/10.1109/ACCESS.2018.2888976>
- Zhu, J., & Liu, W. (2020). A tale of two databases: the use of Web of Science and Scopus in academic papers. *Scientometrics*, 123(1), 321-335. <https://doi.org/10.1007/s11192-020-03387-8>