ReGeo ISSN: 2177-3246

FRAMEWORK INTEGRADO PARA AVALIAÇÃO DA SUSTENTABILIDADE AMBIENTAL DA INTELIGÊNCIA ARTIFICIAL

INTEGRATED FRAMEWORK FOR ASSESSING THE ENVIRONMENTAL SUSTAINABILITY OF ARTIFICIAL INTELLIGENCE

MARCO INTEGRADO PARA LA EVALUACIÓN DE LA SOSTENIBILIDAD AMBIENTAL DE LA INTELIGENCIA ARTIFICIAL

https://doi.org/10.56238/revgeov17n10-183

Data de submissão: 26/09/2026 **Data de publicação:** 26/10/2026

Danielle Aparecida Alcântara
Doutoranda em Administração
Instituição: Universidade Federal de Lavras (UFLA)
E-mail: danielle.a.alcantara@gmail.com
Orcid: https://orcid.org/0000-0002-0421-6613
Lattes: http://lattes.cnpq.br/7334555681922866

Tainara Gomes Cândida da Silva
Mestranda em Administração
Instituição: Universidade Federal de Lavras (UFLA)
E-mail: tainaracandida1@gmail.com
Orcid: https://orcid.org/0009-0000-3791-0487
Lattes: http://lattes.cnpq.br/6122402866733581

Alessandro Silva de Oliveira
Doutor em Administração
Instituição: Universidade Federal de Lavras (UFLA)
E-mail: alessandrooliveira@ufla.br
Orcid: https://orcid.org/0000-0001-8148-0621
Lattes: http://lattes.cnpq.br/4743590121592141

Lilia Paula Andrade
Doutora em Administração
Instituição: Universidade Federal de Lavras (UFLA)
E-mail: lilia.andrade@ufla.br
Orcid: https://orcid.org/0000-0001-7214-2057
Lattes: http://lattes.cnpq.br/1159973786633538

Dany Flavio Tonelli
Doutor em Administração
Instituição: Universidade Federal de Lavras (UFLA)
E-mail: danytonelli@ufla.br
Orcid: https://orcid.org/0000-0002-4307-6430
Lattes: http://lattes.cnpq.br/1549447568023040

RESUMO
A expansão da Inteligência Artificial (IA), especialmente dos modelos fundacionais e dos Grandes Modelos de Linguagem, tem ampliado a demanda por infraestrutura computacional, energia elétrica e recursos associados aos data centers. Este estudo tem como objetivo desenvolver um framework integrado para avaliação da sustentabilidade ambiental de sistemas de IA, articulando infraestrutura computacional, indicadores energéticos, indicadores ambientais e Objetivos de Desenvolvimento Sustentável (ODS). A pesquisa é aplicada e exploratória, conduzida sob a perspectiva da Design Science Research (DSR), com operacionalização baseada em Peffers *et al.* (2007) e articulação com o Three Cycle View de Hevner (2007). O ciclo de rigor é sustentado por revisão integrativa da literatura, com estratégia de busca estruturada, critérios de inclusão e exclusão e análise temática dos estudos. O suporte quantitativo do artefato considera consumo de energia, Power Usage Effectiveness (PUE), intensidade de carbono e emissões de CO_2. Como resultado, propõe-se um framework composto por quatro dimensões interdependentes: infraestrutura computacional, indicadores energéticos, indicadores ambientais e sustentabilidade, esta última relacionada prioritariamente aos ODS 7, 9, 12 e 13. A avaliação realizada nesta etapa é analítica e ex ante, baseada em completude, rastreabilidade, coerência interna, operacionalizabilidade e alinhamento. O estudo contribui ao integrar métricas dispersas em uma estrutura conceitual única e explicita como o artefato poderá ser posteriormente validado por especialistas e aplicado em estudos de caso com dados reais.

Palavras-chave: Inteligência Artificial. Sustainable AI. Green AI. Sustentabilidade Ambiental. Design Science Research.

ABSTRACT
The expansion of Artificial Intelligence (AI), particularly foundation models and Large Language Models, has increased the demand for computing infrastructure, electricity, and data-center resources. This study aims to develop an integrated framework for assessing the environmental sustainability of AI systems by articulating computing infrastructure, energy indicators, environmental indicators, and the Sustainable Development Goals (SDGs). The research is applied and exploratory and follows a Design Science Research (DSR) approach, operationalized through Peffers *et al.* (2007) and articulated with Hevner's (2007) Three Cycle View. The rigor cycle is supported by an integrative literature review with a structured search strategy, inclusion and exclusion criteria, and thematic analysis. The quantitative support of the artifact considers energy consumption, Power Usage Effectiveness (PUE), carbon intensity, and CO_2e emissions. The resulting framework comprises four interdependent dimensions: computing infrastructure, energy indicators, environmental indicators, and sustainability, with the latter primarily linked to SDGs 7, 9, 12, and 13. At this stage, the artifact is evaluated analytically and ex ante according to completeness, traceability, internal coherence, operationalizability, and alignment. The study contributes by integrating dispersed metrics into a single conceptual structure and by specifying how the artifact can subsequently be validated by experts and applied in case studies using real-world data.

Keywords: Artificial Intelligence. Sustainable AI. Green AI. Environmental Sustainability. Design Science Research.

RESUMEN
La expansión de la Inteligencia Artificial (IA), especialmente de los modelos fundacionales y de los Grandes Modelos de Lenguaje, ha incrementado la demanda de infraestructura computacional, energía eléctrica y recursos asociados a los centros de datos. Este estudio tiene como objetivo desarrollar un marco integrado para evaluar la sostenibilidad ambiental de los sistemas de IA, articulando infraestructura computacional, indicadores energéticos, indicadores ambientales y Objetivos de

Desarrollo Sostenible (ODS). La investigación es aplicada y exploratoria y se desarrolla desde la perspectiva de Design Science Research (DSR), operacionalizada con base en Peffers *et al.* (2007) y articulada con el Three Cycle View de Hevner (2007). El ciclo de rigor se sustenta en una revisión integradora de la literatura con estrategia de búsqueda estructurada, criterios de inclusión y exclusión y análisis temático. El soporte cuantitativo del artefacto considera consumo de energía, Power Usage Effectiveness (PUE), intensidad de carbono y emisiones de CO_2e. Como resultado, se propone un marco compuesto por cuatro dimensiones interdependientes: infraestructura computacional, indicadores energéticos, indicadores ambientales y sostenibilidad, esta última vinculada prioritariamente con los ODS 7, 9, 12 y 13. La evaluación realizada en esta etapa es analítica y ex ante, basada en completitud, trazabilidad, coherencia interna, operacionalización y alineación. El estudio contribuye al integrar métricas dispersas en una estructura conceptual única y explicita cómo el artefacto podrá validarse posteriormente con especialistas y aplicarse en estudios de caso con datos reales.

Palabras clave: Inteligencia Artificial. Sustainable AI. Green AI. Sostenibilidad Ambiental. Design Science Research.

1 INTRODUÇÃO

A Inteligência Artificial (IA) consolidou-se como uma tecnologia de propósito geral da atual transformação digital, com aplicações em sistemas produtivos, inovação organizacional, serviços e pesquisa científica. O avanço do aprendizado profundo, dos modelos fundacionais e dos Grandes Modelos de Linguagem (Large Language Models – LLMs) ampliou a capacidade computacional necessária ao treinamento e à inferência, tornando o consumo de energia e as emissões associadas parte relevante da discussão sobre o desenvolvimento responsável da IA (LeCun; Bengio; Hinton, 2015; Brown *et al.*, 2020; Bommasani *et al.*, 2021).

Segundo a International Energy Agency (IEA, 2025), os data centers consumiram aproximadamente 415 TWh de eletricidade em 2024, cerca de 1,5% da demanda mundial, e o cenário de referência da agência projeta aproximadamente 945 TWh em 2030. A expansão da IA, em especial da IA generativa e de servidores acelerados por GPUs, figura entre os principais vetores desse crescimento. O impacto, entretanto, não se limita ao processamento: armazenamento, redes, distribuição elétrica e refrigeração também influenciam a energia total requerida e, consequentemente, as emissões de gases de efeito estufa.

Esse cenário evidencia um paradoxo: a IA pode apoiar soluções para desafios sociais, econômicos e ambientais, mas sua expansão também pode ampliar a própria pegada ambiental. O debate inicialmente associado à Green AI, que propõe incorporar eficiência computacional, energia e emissões à avaliação dos modelos (Schwartz *et al.*, 2020), vem sendo ampliado pela Sustainable AI, cuja perspectiva considera o sistema de forma mais abrangente, incluindo infraestrutura, matriz elétrica, ciclo de vida e efeitos organizacionais e sociais (Bolón-Canedo *et al.*, 2024; Tabbakh *et al.*, 2024).

A literatura oferece métricas e ferramentas para mensurar partes desse problema, como Green Algorithms, CodeCarbon e CarbonTracker, mas emprega parâmetros, fronteiras e fatores de emissão distintos. Também há diferenças quanto à consideração do treinamento, da inferência, do Power Usage Effectiveness (PUE), da intensidade de carbono local e do ciclo de vida do hardware (Anthony; Kanding; Selvan, 2020; Henderson *et al.*, 2020; Lannelongue; Grealey; Inouye, 2021; Patterson *et al.*, 2021; Courty *et al.*, 2024). Essa fragmentação reduz a comparabilidade e dificulta uma leitura integrada da sustentabilidade ambiental da IA.

Além disso, indicadores técnicos raramente são articulados, em uma mesma estrutura analítica, às metas da Agenda 2030. Neste estudo, a conexão é delimitada aos ODS 7 (Energia Acessível e Limpa), 9 (Indústria, Inovação e Infraestrutura), 12 (Consumo e Produção Responsáveis) e 13 (Ação

Contra a Mudança Global do Clima), por apresentarem relação direta com energia, infraestrutura, eficiência no uso de recursos e emissões (United Nations, 2015; Vinuesa *et al.*, 2020).

Diante dessa lacuna, a questão central de pesquisa é: como integrar, em um framework conceitual único, variáveis de infraestrutura computacional, consumo energético, eficiência de data centers, emissões de carbono e sustentabilidade para apoiar a avaliação ambiental de sistemas de IA? Como questões complementares, investigam-se: (Q1) quais construtos e indicadores são recorrentes na literatura de Green AI e Sustainable AI?; (Q2) como esses elementos podem ser organizados em dimensões analíticas interdependentes?; e (Q3) como relacionar os indicadores técnicos aos ODS 7, 9, 12 e 13?

Por se tratar de uma pesquisa de construção de artefato conceitual, não são formuladas hipóteses estatísticas. Em seu lugar, adotam-se proposições de design: (P1) a sustentabilidade ambiental da IA requer avaliação conjunta da infraestrutura e do uso computacional; (P2) consumo energético deve ser interpretado em conjunto com a eficiência da infraestrutura; (P3) emissões dependem da energia consumida e da intensidade de carbono da eletricidade; e (P4) a interpretação dos resultados deve ser conectada a objetivos de sustentabilidade. O objetivo geral é desenvolver e avaliar analiticamente um framework integrado para a sustentabilidade ambiental de sistemas de IA, contemplando treinamento e inferência e articulando indicadores técnicos aos ODS 7, 9, 12 e 13.

2 REFERENCIAL TEÓRICO

2.1 INTELIGÊNCIA ARTIFICIAL, INFRAESTRUTURA DIGITAL E CONSUMO ENERGÉTICO

A IA contemporânea evoluiu de sistemas especializados para modelos fundacionais reutilizáveis em múltiplas tarefas. Essa mudança ampliou a generalização e a escala de uso, mas também aumentou a demanda por aceleradores, memória, armazenamento e processamento distribuído (Brown *et al.*, 2020; Bommasani *et al.*, 2021; Patterson *et al.*, 2021). Assim, a infraestrutura computacional passou a ser parte constitutiva do desempenho ambiental dos sistemas inteligentes.

O consumo energético resulta da interação entre arquitetura do modelo, hardware, taxa de utilização, duração do treinamento, volume de inferências e características do data center. A inferência merece atenção porque ocorre repetidamente durante a vida útil do modelo e pode acumular consumo expressivo em aplicações de grande escala. Além da carga de TI, sistemas auxiliares de refrigeração, armazenamento e distribuição elétrica ampliam a energia total requerida. Nesse contexto, o PUE representa a razão entre a energia total consumida pela instalação e a energia destinada aos equipamentos de TI; quanto mais próximo de 1, maior a eficiência operacional da infraestrutura (Lannelongue; Grealey; Inouye, 2021; Patterson *et al.*, 2021).

Ferramentas como Green Algorithms, CodeCarbon e CarbonTracker apoiam a mensuração do consumo e das emissões, mas utilizam pressupostos e fontes de dados que podem variar. Henderson *et al.* (2020) defendem maior padronização do reporte energético, condição importante para transparência, reprodutibilidade e comparação entre experimentos.

2.2 EMISSÕES DE CARBONO E AVALIAÇÃO AMBIENTAL

O consumo de eletricidade, isoladamente, não representa o impacto climático de um sistema de IA. A mesma quantidade de energia pode gerar emissões distintas conforme a matriz elétrica. Por isso, a avaliação deve combinar energia consumida, eficiência da infraestrutura e fator de emissão ou intensidade de carbono local, expressando o resultado em dióxido de carbono equivalente (CO_2e) (Henderson *et al.*, 2020; Patterson *et al.*, 2021).

Uma formulação operacional simplificada pode ser representada por:

$$E_{\text{total}} = E_{\text{TI}} \times \text{PUE} \qquad (1)$$

em que ETI corresponde à energia diretamente associada aos recursos computacionais e Etotal incorpora a sobrecarga da infraestrutura. As emissões operacionais podem ser estimadas por:

$$\text{CO}_2\text{e} = E_{\text{total}} \times \text{IC} \qquad (2)$$

em que IC representa a intensidade de carbono da eletricidade, em $kgCO_2e/kWh$. Quando houver medição direta da energia total do data center, o PUE não deve ser aplicado novamente, evitando dupla contabilização.

A definição das fronteiras também é relevante. Uma avaliação operacional considera treinamento e inferência; uma avaliação ampliada pode incorporar fabricação, transporte, manutenção e descarte do hardware segundo princípios de Avaliação do Ciclo de Vida (LCA). As normas ISO 14040 e ISO 14044 oferecem fundamentos para essa ampliação, enquanto a ISO 14064-1 fornece referência para quantificação e reporte de gases de efeito estufa.

2.3 GREEN AI, SUSTAINABLE AI E OBJETIVOS DE DESENVOLVIMENTO SUSTENTÁVEL

Green AI propõe deslocar a avaliação de modelos de uma lógica centrada exclusivamente em desempenho preditivo para uma lógica que também considere custo computacional, energia e emissões (Schwartz *et al.*, 2020). A literatura posterior diferencia abordagens voltadas a reduzir os impactos da

própria IA (Green-in AI) daquelas que utilizam IA para promover sustentabilidade em outros domínios (Green-by AI) (Bolón-Canedo *et al.*, 2024).

Sustainable AI amplia essa perspectiva ao considerar o ciclo de vida, a infraestrutura e dimensões de governança, ainda que o campo apresente variações terminológicas e de escopo (Verdecchia; Sallou; Cruz, 2023; Tabbakh *et al.*, 2024). Para a finalidade deste estudo, o foco é ambiental e operacional, com possibilidade de expansão futura para impactos incorporados do hardware.

A articulação com os ODS permite interpretar métricas técnicas em uma agenda mais ampla: o ODS 7 se relaciona à eficiência e à origem da energia; o ODS 9, à infraestrutura digital eficiente e resiliente; o ODS 12, ao uso responsável de recursos e ao ciclo de vida; e o ODS 13, à redução e ao reporte de emissões. Essa articulação não transforma os ODS em métricas de desempenho, mas os utiliza como camada interpretativa para os indicadores ambientais (United Nations, 2015; Vinuesa *et al.*, 2020).

3 METODOLOGIA

3.1 DELINEAMENTO E LÓGICA DA DESIGN SCIENCE RESEARCH

A pesquisa é aplicada, exploratória e desenvolvida sob a perspectiva da Design Science Research (DSR), pois busca construir um artefato conceitual destinado a organizar e integrar conhecimentos para um problema relevante. O artefato é um framework conceitual, e não um sistema computacional. A abordagem é predominantemente qualitativa na identificação, codificação e integração dos construtos, com suporte quantitativo na operacionalização dos indicadores energéticos e ambientais que compõem o framework (Hevner *et al.*, 2004; Gregor; Hevner, 2013).

A operacionalização segue as seis atividades de Peffers *et al.* (2007) (Figura 1): (1) identificação do problema e motivação, caracterizada pela fragmentação das métricas de sustentabilidade ambiental da IA; (2) definição dos objetivos da solução, traduzidos na necessidade de integrar infraestrutura, energia, emissões e sustentabilidade; (3) design e desenvolvimento, mediante seleção, codificação e organização dos construtos; (4) demonstração, realizada pela representação do fluxo de avaliação e pela explicitação das fórmulas e dados de entrada; (5) avaliação, conduzida nesta etapa por avaliação analítica ex ante baseada em critérios de completude, rastreabilidade, coerência interna, operacionalizabilidade e alinhamento aos ODS; e (6) comunicação, materializada na apresentação do framework, de seus indicadores, limitações e agenda de validação empírica.

Complementarmente, o Three Cycle View de Hevner (2007) orienta a articulação entre o Ciclo de Relevância, associado ao problema prático; o Ciclo de Rigor, sustentado pela revisão integrativa e

por normas e métodos consolidados; e o Ciclo de Design, no qual o artefato é construído, demonstrado e avaliado iterativamente. A avaliação realizada neste artigo é analítica e conceitual; portanto, não se afirma validação externa por especialistas nem validação em estudo de caso. Essas formas de validação constituem a etapa empírica subsequente da agenda de pesquisa.

3.2 REVISÃO INTEGRATIVA: BASES, ESTRATÉGIA DE BUSCA E CRITÉRIOS

A revisão integrativa constitui a principal fonte do Ciclo de Rigor. Foram consultadas Scopus, Web of Science Core Collection, IEEE Xplore, ScienceDirect, SpringerLink e ACM Digital Library, além de documentos técnicos da IEA, United Nations, UNESCO, ISO e Green Software Foundation. Não foi adotado corte temporal rígido, de modo a preservar trabalhos seminais e incorporar publicações recentes disponíveis até 2025. A seleção seguiu lógica compatível com PRISMA 2020, adaptada à finalidade integrativa do estudo (Whittemore; Knafl, 2005; Page *et al.*, 2021).

A string-base foi estruturada em três blocos e adaptada à sintaxe de cada base: (“artificial intelligence” OR “green AI” OR “green artificial intelligence” OR “sustainable AI” OR “sustainable artificial intelligence”) AND (“energy consumption” OR “energy efficiency” OR “carbon emissions” OR “carbon footprint” OR “power usage effectiveness” OR PUE OR “life cycle assessment”) AND (sustainability OR “sustainable development goals” OR “data center”). Buscas complementares foram realizadas a partir das referências dos estudos selecionados e de documentos técnicos necessários à definição de métricas.

Foram incluídos artigos revisados por pares e trabalhos de conferências que abordassem consumo energético, eficiência, emissões, infraestrutura, Green AI, Sustainable AI ou avaliação ambiental da IA, além de documentos institucionais diretamente relacionados às métricas utilizadas. Foram excluídos duplicados, estudos sem relação direta com o problema, documentos sem acesso ao texto completo e literatura não revisada por pares, excetuados padrões, normas e relatórios técnicos institucionais. De cada estudo foram extraídos objetivo, método, unidade de análise, variáveis, indicadores, fórmulas, fontes de dados, fronteiras de avaliação, limitações e contribuições.

Os elementos extraídos foram submetidos à análise temática, com codificação, agrupamento de sinônimos e identificação de relações conceituais (Braun; Clarke, 2006). A recorrência na literatura foi utilizada como evidência de consolidação conceitual, mas não como critério estatístico de representatividade. O resultado da síntese foi organizado em uma matriz de rastreabilidade que relaciona dimensão, construto, variável, forma de operacionalização e fundamentação teórica.

3.3 OPERACIONALIZAÇÃO QUANTITATIVA DOS INDICADORES

O suporte quantitativo do framework é operacionalizado por dados mensuráveis ou estimáveis. Para cada execução de treinamento ou inferência, registram-se, quando disponíveis: tipo e quantidade de CPU/GPU/TPU; potência média ou energia medida; taxa de utilização; duração da execução; número de inferências; localização do data center; PUE; e intensidade de carbono da eletricidade. A energia de TI pode ser obtida por telemetria direta ou estimada por:

$$E_{\mathrm{TI}} = \sum_i (P_i \times U_i \times t) \qquad (3)$$

em que Pi é a potência média do dispositivo i, Ui é sua fração de utilização e t é o tempo de execução em horas.

Quando a medição se restringe à carga de TI, a energia total é estimada pela Equação (1). As emissões operacionais são calculadas pela Equação (2). Para inferência, recomenda-se ainda o indicador:

$$E_{\mathrm{inf}} = \frac{E_{\mathrm{total}}}{N} \qquad (4)$$

em que N é o número de consultas ou inferências processadas, permitindo comparação entre cargas de trabalho. Os resultados devem registrar fonte, período e localização do fator de emissão, pois a intensidade de carbono varia temporal e geograficamente.

Os dados podem ser coletados por ferramentas como CodeCarbon, CarbonTracker ou Green Algorithms, por telemetria do provedor de nuvem, por medidores da infraestrutura ou por especificações técnicas, desde que a fonte e as premissas sejam explicitadas. O framework distingue dados observados de dados estimados e exige registro da fronteira de cálculo, evitando comparar valores obtidos por escopos diferentes.

3.4 AVALIAÇÃO DO ARTEFATO

A avaliação do framework nesta etapa é ex ante e analítica. Cinco critérios foram aplicados à estrutura: (i) completude, verificando se as dimensões cobrem os principais elementos identificados na revisão; (ii) rastreabilidade, verificando se cada construto possui fundamentação explícita; (iii) coerência interna, examinando a consistência das relações entre infraestrutura, energia, emissões e sustentabilidade; (iv) operacionalizabilidade, verificando se os principais indicadores possuem dados

de entrada, unidade e regra de cálculo identificáveis; e (v) alinhamento, examinando a correspondência interpretativa com os ODS 7, 9, 12 e 13.

Essa estratégia permite avaliar a consistência lógica do artefato sem confundir construção conceitual com validação empírica. Como etapa posterior, recomenda-se uma avaliação ex post em duas fases: painel de especialistas, com roteiro estruturado e possibilidade de técnica Delphi para examinar relevância, clareza e completude; e aplicação em estudo de caso, comparando sistemas ou cargas de IA a partir de dados reais de energia, PUE e intensidade de carbono.

Figura 1. Processo metodológico da pesquisa baseado em Design Science Research (DSR).

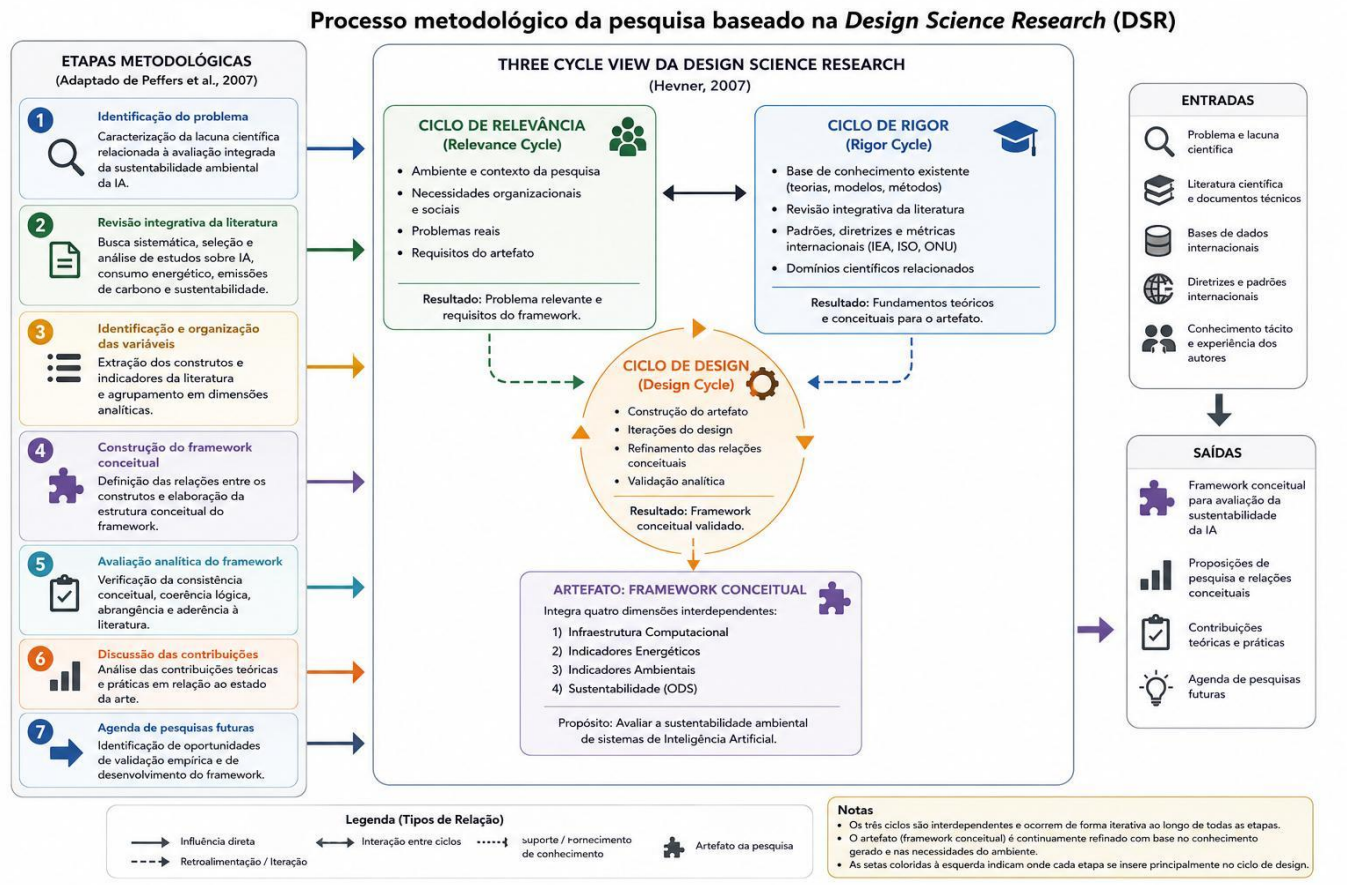

Fonte: Elaborado pelos autores

4 RESULTADOS E DISCUSSÃO

4.1 IDENTIFICAÇÃO E ORGANIZAÇÃO DAS VARIÁVEIS

A análise temática consolidou os elementos identificados na literatura em quatro dimensões interdependentes: Infraestrutura Computacional, Indicadores Energéticos, Indicadores Ambientais e Sustentabilidade. A primeira reúne os recursos físicos e as características do ambiente de execução; a segunda representa consumo e eficiência; a terceira traduz consumo em impactos ambientais; e a quarta interpreta os resultados à luz dos ODS selecionados.

A dimensão Infraestrutura Computacional contempla CPU, GPU, TPU, memória, armazenamento, número de aceleradores, localização e características do data center. Indicadores Energéticos incluem consumo total e por unidade funcional, potência, duração do treinamento e da inferência e eficiência computacional. Indicadores Ambientais incluem CO_2e, intensidade de carbono, fator de emissão, PUE e, quando a fronteira for ampliada, elementos de LCA. A dimensão Sustentabilidade conecta os resultados aos ODS 7, 9, 12 e 13 e aos princípios de Green AI e Sustainable AI.

A rastreabilidade é importante porque impede que o framework se torne uma coleção arbitrária de métricas. Cada construto decorre de evidências recorrentes ou de normas aplicáveis, e sua função no modelo é explicitada. O Quadro 1 sintetiza essa relação.

Quadro 1. Rastreabilidade das variáveis que compõem o framework conceitual.

Dimensão	**Construto**	**Principais variáveis**	**Fundamentação**
Infraestrutura Computacional	Recursos computacionais	CPU, GPU, TPU, memória, armazenamento, nº de aceleradores, localização	Patterson *et al.* (2021); IEA (2025); Henderson *et al.* (2020)
Infraestrutura Computacional	Eficiência da infraestrutura	PUE; arquitetura e refrigeração do data center	Lannelongue; Grealey; Inouye (2021); Patterson *et al.* (2021)
Indicadores Energéticos	Consumo energético	kWh; potência; tempo de treinamento; tempo de inferência	Schwartz *et al.* (2020); Henderson *et al.* (2020); Courty *et al.* (2024)
Indicadores Energéticos	Eficiência computacional	Energia/treinamento; energia/inferência; utilização	Schwartz *et al.* (2020); Green Software Foundation (2024)
Indicadores Ambientais	Emissões de carbono	CO_2e; intensidade de carbono; fator de emissão	Patterson *et al.* (2021); Lannelongue; Grealey; Inouye (2021); ISO 14064-1:2018
Indicadores Ambientais	Avaliação ambiental	LCA; consumo de recursos; fronteira do sistema	ISO 14040:2006; ISO 14044:2006
Sustentabilidade	Alinhamento aos ODS	ODS 7, 9, 12 e 13; Green AI; Sustainable AI	United Nations (2015); Vinuesa *et al.* (2020); Bolón-Canedo *et al.* (2024)

Fonte: Elaborado pelos autores com base na literatura.

4.2 CONSTRUÇÃO, DEMONSTRAÇÃO E AVALIAÇÃO ANALÍTICA DO FRAMEWORK

O framework foi estruturado como uma cadeia de avaliação (Figura 2). A infraestrutura define os recursos e o contexto de execução; os indicadores energéticos quantificam a energia associada ao treinamento e à inferência; os indicadores ambientais convertem a energia em emissões considerando PUE e intensidade de carbono; e a dimensão de sustentabilidade interpreta os resultados segundo os

ODS. Essa lógica torna explícitas as dependências entre variáveis e reduz o risco de tratar consumo, eficiência e emissões como medidas equivalentes.

A demonstração pode ser realizada para qualquer carga de IA para a qual estejam disponíveis, no mínimo, energia de TI ou potência e tempo, PUE quando aplicável, localização e intensidade de carbono. Por exemplo, a comparação entre duas execuções deve manter explícita a unidade funcional - treinamento completo, hora de processamento ou número de inferências - e a mesma fronteira de sistema. Dessa forma, o framework não substitui ferramentas de medição, mas organiza seus resultados em uma estrutura comparável e auditável.

Na avaliação analítica, a completude é atendida pela presença das quatro dimensões derivadas da revisão; a rastreabilidade é evidenciada no Quadro 1; a coerência interna decorre da sequência infraestrutura → energia → emissões → interpretação; a operacionalizabilidade é sustentada pelas variáveis e equações apresentadas; e o alinhamento é estabelecido pela correspondência entre indicadores e ODS. O resultado é uma avaliação conceitual do artefato, e não uma validação empírica de sua eficácia em contextos organizacionais.

Figura 2. Framework conceitual para avaliação da sustentabilidade ambiental da Inteligência Artificial.

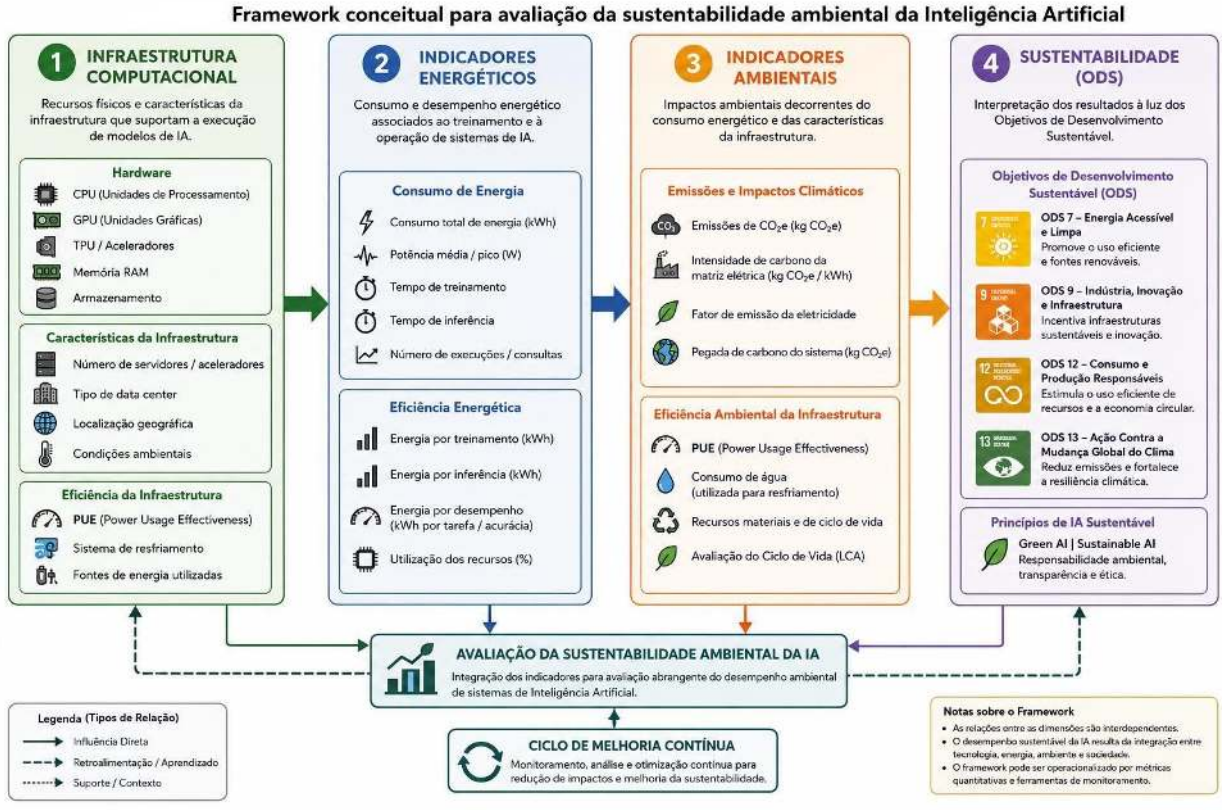

Fonte: Elaborado pelos autores

5 CONCLUSÃO

Este estudo desenvolveu um framework conceitual para integrar infraestrutura computacional, consumo energético, eficiência da infraestrutura, emissões de carbono e sustentabilidade ambiental da Inteligência Artificial. A proposta responde à fragmentação identificada na literatura ao explicitar uma cadeia analítica que parte dos recursos computacionais, passa pela mensuração energética e ambiental e culmina na interpretação dos resultados à luz dos ODS 7, 9, 12 e 13.

A contribuição teórica está na organização e na rastreabilidade das relações entre construtos de Green AI, Sustainable AI, eficiência de data centers e avaliação ambiental. A contribuição metodológica consiste em explicitar dados de entrada, unidades e relações de cálculo para energia, PUE, intensidade de carbono e CO_2e. Em termos práticos, o framework pode orientar organizações na estruturação do diagnóstico ambiental de cargas de IA, desde que as fontes de dados, as fronteiras do sistema e as premissas de cálculo sejam documentadas.

A avaliação realizada nesta pesquisa é analítica e ex ante. O artefato ainda não foi validado externamente por especialistas nem aplicado a um estudo de caso com dados primários, o que limita conclusões sobre utilidade, facilidade de uso e capacidade discriminante em ambientes reais. Também permanecem desafios relacionados à disponibilidade de dados de provedores, à variação temporal da intensidade de carbono e à mensuração de impactos incorporados no hardware.

Como agenda futura, recomenda-se validar o framework com especialistas por meio de Delphi ou grupo focal e, em seguida, aplicá-lo em estudos de caso com cargas reais de treinamento e inferência. Essa etapa permitirá testar a clareza dos construtos, a viabilidade de coleta dos indicadores e a sensibilidade do modelo a diferentes combinações de hardware, PUE e matriz elétrica. Também se recomenda ampliar a fronteira para avaliação de ciclo de vida e incorporar dimensões sociais e de governança, aproximando o artefato de uma concepção mais abrangente de Sustainable AI.

AGRADECIMENTOS

Este estudo foi realizado com apoio pelo Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior. Agradecimentos à Universidade Federal de Lavras (UFLA) pelo apoio técnico e didático.

REFERÊNCIAS

ANTHONY, L. F. W.; KANDING, B.; SELVAN, R. CarbonTracker: tracking and predicting the carbon footprint of training deep learning models. arXiv, 2020. DOI: 10.48550/arXiv.2007.03051.

BOLÓN-CANEDO, V. *et al.* A review of green artificial intelligence: towards a more sustainable future. Neurocomputing, v. 599, art. 128096, 2024. DOI: 10.1016/j.neucom.2024.128096.

BOMMASANI, R. *et al.* On the opportunities and risks of foundation models. arXiv, 2021. DOI: 10.48550/arXiv.2108.07258.

BRAUN, V.; CLARKE, V. Using thematic analysis in psychology. Qualitative Research in Psychology, v. 3, n. 2, p. 77-101, 2006. DOI: 10.1191/1478088706qp063oa.

BROWN, T. B. *et al.* Language models are few-shot learners. Advances in Neural Information Processing Systems, v. 33, p. 1877-1901, 2020.

BRYNJOLFSSON, E.; MCAFEE, A. The business of artificial intelligence. Harvard Business Review, 18 jul. 2017.

COURTY, B. *et al.* CodeCarbon: a Python package to track and reduce carbon emissions from computing. Journal of Open Source Software, v. 9, n. 93, art. 6048, 2024. DOI: 10.21105/joss.06048.

GREEN SOFTWARE FOUNDATION. Software Carbon Intensity (SCI) specification. 2024.

GREGOR, S. The nature of theory in information systems. MIS Quarterly, v. 30, n. 3, p. 611-642, 2006. DOI: 10.2307/25148742.

GREGOR, S.; HEVNER, A. R. Positioning and presenting design science research for maximum impact. MIS Quarterly, v. 37, n. 2, p. 337-355, 2013. DOI: 10.25300/MISQ/2013/37.2.01.

HENDERSON, P. *et al.* Towards the systematic reporting of the energy and carbon footprints of machine learning. Journal of Machine Learning Research, v. 21, n. 248, p. 1-43, 2020.

HEVNER, A. R. A three cycle view of design science research. Scandinavian Journal of Information Systems, v. 19, n. 2, p. 87-92, 2007.

HEVNER, A. R. *et al.* Design science in information systems research. MIS Quarterly, v. 28, n. 1, p. 75-105, 2004. DOI: 10.2307/25148625.

INTERNATIONAL ENERGY AGENCY. Energy and AI. Paris: IEA, 2025.

INTERNATIONAL ORGANIZATION FOR STANDARDIZATION. ISO 14040:2006: Environmental management - Life cycle assessment - Principles and framework. Geneva: ISO, 2006.

INTERNATIONAL ORGANIZATION FOR STANDARDIZATION. ISO 14044:2006: Environmental management - Life cycle assessment - Requirements and guidelines. Geneva: ISO, 2006.

INTERNATIONAL ORGANIZATION FOR STANDARDIZATION. ISO 14064-1:2018: Greenhouse gases - Part 1: Specification with guidance at the organization level for quantification and reporting of greenhouse gas emissions and removals. Geneva: ISO, 2018.

LANNELONGUE, L.; GREALEY, J.; INOUYE, M. Green Algorithms: quantifying the carbon footprint of computation. Advanced Science, v. 8, n. 12, art. 2100707, 2021. DOI: 10.1002/advs.202100707.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. Nature, v. 521, n. 7553, p. 436-444, 2015. DOI: 10.1038/nature14539.

PAGE, M. J. *et al.* The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. BMJ, v. 372, art. n71, 2021. DOI: 10.1136/bmj.n71.

PATTERSON, D. *et al.* Carbon emissions and large neural network training. arXiv, 2021. DOI: 10.48550/arXiv.2104.10350.

PEFFERS, K. *et al.* A design science research methodology for information systems research. Journal of Management Information Systems, v. 24, n. 3, p. 45-77, 2007. DOI: 10.2753/MIS0742-1222240302.

SCHWARTZ, R. *et al.* Green AI. Communications of the ACM, v. 63, n. 12, p. 54-63, 2020. DOI: 10.1145/3381831.

TABBAKH, A. *et al.* Towards sustainable AI: a comprehensive framework for Green AI. Discover Sustainability, v. 5, art. 408, 2024. DOI: 10.1007/s43621-024-00641-4.

UNITED NATIONS. Transforming our world: the 2030 Agenda for Sustainable Development. New York: United Nations, 2015.

VERDECCHIA, R.; SALLOU, J.; CRUZ, L. A systematic review of Green AI. WIREs Data Mining and Knowledge Discovery, v. 13, n. 4, art. e1507, 2023. DOI: 10.1002/widm.1507.

VINUESA, R. *et al.* The role of artificial intelligence in achieving the Sustainable Development Goals. Nature Communications, v. 11, art. 233, 2020. DOI: 10.1038/s41467-019-14108-y.

WHITTEMORE, R.; KNAFL, K. The integrative review: updated methodology. Journal of Advanced Nursing, v. 52, n. 5, p. 546-553, 2005. DOI: 10.1111/j.1365-2648.2005.03621.x.