



**UNIVERSIDADE FEDERAL DO CEARÁ**  
**CENTRO DE TECNOLOGIA**  
**DEPARTAMENTO DE ENGENHARIA MECÂNICA**  
**CURSO DE ENGENHARIA DE ENERGIAS RENOVÁVEIS**

**LEANDRO DA SILVA COSTA**

**INTELIGÊNCIA ARTIFICIAL E SUSTENTABILIDADE ENERGÉTICA: IMPACTO  
AMBIENTAL DO CONSUMO E COMPENSAÇÃO COM ENERGIA SOLAR**

**FORTALEZA**

**2025**

LEANDRO DA SILVA COSTA

INTELIGÊNCIA ARTIFICIAL E SUSTENTABILIDADE ENERGÉTICA: IMPACTO  
AMBIENTAL DO CONSUMO E COMPENSAÇÃO COM ENERGIA SOLAR

Trabalho de conclusão de curso apresentado ao  
Curso de Graduação em Engenharia de Energias  
Renováveis da Universidade Federal do Ceará,  
como requisito parcial à obtenção do título de  
Engenheiro em Engenharia de Energias  
Renováveis.

Orientador: Prof.<sup>a</sup> Dra. Ana Fabíola Leite  
Almeida.

FORTALEZA

2025

Dados Internacionais de Catalogação na Publicação  
Universidade Federal do Ceará  
Sistema de Bibliotecas  
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

---

- C873i Costa, Leandro da Silva.  
Inteligência artificial e sustentabilidade energética : impacto ambiental do consumo e compensação com energia solar / Leandro da Silva Costa. – 2025.  
39 f. : il. color.
- Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Centro de Tecnologia, Curso de Engenharia de Energias Renováveis, Fortaleza, 2025.  
Orientação: Profa. Dra. Ana Fabíola Leite Almeida.
1. Inteligência artificial. 2. Consumo energético. 3. Impacto ambiental. 4. Sustentabilidade. 5. Energia solar fotovoltaica. I. Título.

CDD 621.042

---

LEANDRO DA SILVA COSTA

INTELIGÊNCIA ARTIFICIAL E SUSTENTABILIDADE ENERGÉTICA: IMPACTO  
AMBIENTAL DO CONSUMO E COMPENSAÇÃO COM ENERGIA SOLAR

Trabalho de conclusão de curso apresentado ao  
Curso de Graduação em Engenharia de Energias  
Renováveis da Universidade Federal do Ceará,  
como requisito parcial à obtenção do título de  
Engenheiro em Engenharia de Energias  
Renováveis.

Aprovada em: \_\_/\_\_/\_\_\_\_.

BANCA EXAMINADORA

---

Prof.<sup>a</sup> Dra. Ana Fabíola Leite Almeida (Orientador)  
Universidade Federal do Ceará (UFC)

---

Prof. Dra. Amanda Pereira Monteiro  
Universidade Federal do Ceará (UFC)

---

Prof. Dr. Francisco Nivaldo Aguiar Freire  
Universidade Federal do Ceará (UFC)

A Deus.

Aos meus pais, Silvia e Eraldo.

A minha noiva Bruna Fernandes.

## **AGRADECIMENTOS**

A Prof.<sup>a</sup> Dra. Ana Fabíola Leite Almeida, pela excelente orientação e paciência.

Aos professores participantes da banca examinadora Amanda Pereira Monteiro e Francisco Nivaldo Aguiar Freire pelo tempo, pelas valiosas colaborações e sugestões.

Aos colegas da turma, pelas reflexões, críticas e sugestões recebidas durante a formação.

A minha noiva e companheira durante o tempo da graduação Bruna Fernandes, a todo apoio e suporte.

"O consumo sustentável de energia é fundamental para garantir o desenvolvimento econômico e social sem comprometer o meio ambiente, buscando atender às necessidades presentes sem esgotar os recursos para as gerações futuras" (SILVA, 2020, p. 42).

## RESUMO

Diante do crescente impacto ambiental gerado por sistemas de inteligência artificial (IA), especialmente os modelos de linguagem de grande escala (LLMs), torna-se necessário avaliar estratégias de mitigação desse consumo energético. Considerando o elevado consumo energético durante o treinamento e a inferência desses modelos, estimaram-se as emissões de gases de efeito estufa associadas, com base em diferentes matrizes elétricas. Como proposta de mitigação, foi dimensionado um sistema de energia solar fotovoltaica capaz de compensar integralmente o consumo anual de energia desses sistemas. A análise econômica demonstrou que a proposta apresenta um retorno financeiro atrativo, com recuperação do investimento em menos de cinco anos. Os resultados indicam que a adoção de fontes renováveis para alimentar a IA é uma estratégia eficaz para promover a sustentabilidade tecnológica, conciliando inovação e responsabilidade ambiental.

**Palavras-chave:** Inteligência artificial. Consumo energético. Impacto ambiental. Energia solar fotovoltaica. Sustentabilidade.



## ABSTRACT

Given the growing environmental impact of artificial intelligence (AI) systems, especially large-scale language models (LLMs), it is necessary to evaluate strategies to mitigate this energy consumption. Considering the high energy consumption during the training and inference of these models, the associated greenhouse gas emissions were estimated based on different electricity grids. As a mitigation proposal, a photovoltaic solar energy system capable of fully offsetting the annual energy consumption of these systems was designed. The economic analysis demonstrated that the proposal offers an attractive financial return, with a payback period of less than five years. The results indicate that adopting renewable sources to power AI is an effective strategy for promoting technological sustainability, reconciling innovation and environmental responsibility.

**Keywords:** Artificial intelligence. Energy consumption. Environmental impact. Photovoltaic solar energy. Sustainability.

## LISTA DE FIGURAS

Figura 1 – Campos da Inteligência Artificial.....	15
Figura 2 – Representação esquemática de um Data Center utilizado para treinamento de modelos de IA.....	18

## **LISTA DE GRÁFICOS**

Gráfico 1	– Evolução da média global do PUE.....	16
Gráfico 2	– Distribuição do consumo energético em data centers.....	17

## LISTA DE TABELAS

Tabela 1 – Consumo estimado.....	20
Tabela 2 – Fator médio de emissão de emissão de CO <sub>2</sub> .....	20

## LISTA DE ABREVIATURAS E SIGLAS

<b>ANEEL</b>	Agência Nacional de Energia Elétrica
<b>CO<sub>2</sub></b>	Dióxido de Carbono
<b>GEE</b>	Gases de Efeito Estufa
<b>IA</b>	Inteligência Artificial
<b>IFC</b>	<i>International Finance Corporation</i>
<b>IPCC</b>	<i>Intergovernmental Panel on Climate Change</i>
<b>ONU</b>	Organização das Nações Unidas
<b>P&amp;D</b>	Pesquisa e Desenvolvimento
<b>ROI</b>	<i>Return on Investment</i> (Retorno sobre o Investimento)
<b>UNFCCC</b>	<i>United Nations Framework Convention on Climate Change</i>
<b>ABNT</b>	Associação Brasileira de Normas Técnicas
<b>ANEEL</b>	Agência Nacional de Energia Elétrica
<b>CO<sub>2</sub></b>	Dióxido de Carbono
<b>GEE</b>	Gases de Efeito Estufa
<b>IA</b>	Inteligência Artificial
<b>IFC</b>	<i>International Finance Corporation</i>
<b>IPCC</b>	<i>Intergovernmental Panel on Climate Change</i>
<b>ML</b>	<i>Machine Learning</i> (Aprendizado de Máquina)
<b>LLM</b>	<i>Large Language Models</i> (Grandes Modelos de Linguagem)
<b>GPUs</b>	Unidades de Processamento Gráfico

## LISTA DE SÍMBOLOS

<b>%</b>	Porcentagem
<b>CO<sub>2</sub></b>	Dióxido de carbono (gás de efeito estufa)
<b>kWh</b>	Quilowatt-hora – unidade de energia elétrica
<b>MWh</b>	Megawatt-hora – unidade de energia elétrica (1 MWh = 1.000 kWh)
<b>kWp</b>	Quilowatt-pico – unidade de potência de sistemas fotovoltaicos
<b>MWp</b>	Megawatt-pico – unidade de potência de sistemas fotovoltaicos (1 MWp = 1.000 kWp)
<b>PR</b>	Performance Ratio – razão de desempenho do sistema fotovoltaico
<b>ROI</b>	Return on Investment – Retorno sobre o investimento (%)
<b>Payback</b>	Tempo de retorno do investimento (anos)
<b>H</b>	Irradiação solar média diária (kWh/m <sup>2</sup> /dia)
<b>E</b>	Energia elétrica total a ser compensada (kWh ou MWh)

## Sumário

1 INTRODUÇÃO.....	14
2 FUNDAMENTAÇÃO TEÓRICA.....	19
2.1 Inteligência Artificial e Aprendizado de Máquina.....	20
2.2 Consumo Energético dos Sistemas de IA.....	20
2.3 Impactos Ambientais da Geração de Energia Elétrica.....	21
2.4 Energia Solar Fotovoltaica como Solução Sustentável .....	21
3 RESULTADOS E DISCUSSÃO .....	22
3.1 Estimativa de Consumo Energético e Emissões de CO <sub>2</sub> para Modelos de IA .....	22
3.2 Dimensionamento do Sistema Fotovoltaico Compensatório.....	23
3.3 Viabilidade Econômica.....	24
3.3.1 Custo de Implantação .....	24
3.3.2 Economia Anual Estimada.....	24
3.3.2.1 Análise de Sensibilidade da Rentabilidade do Sistema Fotovoltaico .....	25
3.3.2.2 Viabilidade de Replicação em Data Centers com Limitação de Espaço Físico .....	26
3.3.2.3 Considerações Sobre Armazenamento de Energia no Contexto da Compensação Fotovoltaica .....	27
3.3.3 Tempo de Retorno do Investimento (Payback) .....	28
3.3.4 Retorno sobre o Investimento (ROI) .....	28
3.4 Benefícios Ambientais e Estratégicos da Compensação com Energia Solar.....	29
3.4.1 Benefícios Ambientais:.....	29
3.4.2 Benefícios Estratégicos: .....	30
3.5 Discussão Geral .....	30
4. CONCLUSÃO.....	31
4.1 Avaliação geral do impacto ambiental.....	31
4.2 Viabilidade da solução proposta .....	31
4.3 Limitações e sugestões para estudos futuros .....	32
4.4 Barreiras Políticas e Regulatórias.....	33
4.4 Considerações finais .....	34
5. REFERÊNCIAS .....	36

## 1 INTRODUÇÃO

Ao longo das últimas décadas, a Inteligência Artificial (IA) deixou de ser uma promessa futurista ou uma ideia restrita à ficção científica para se consolidar como uma das tecnologias mais revolucionárias e onipresentes da sociedade contemporânea. A origem da IA remonta à década de 1950, quando pesquisadores como Alan Turing, John McCarthy e Marvin Minsky começaram a especular sobre a possibilidade de máquinas pensarem e aprenderem de forma semelhante à cognição humana. Em 1956, durante a Conferência de Dartmouth, o termo “inteligência artificial” foi formalmente proposto, marcando o início oficial de uma área interdisciplinar que combinava matemática, lógica, ciência da computação, psicologia e filosofia (RUSSELL; NORVIG, 2021).

Nas décadas seguintes, o campo da IA passou por ciclos alternados de entusiasmo e ceticismo. Os primeiros sistemas, baseados em regras lógicas e programação simbólica, mostraram-se eficazes em contextos controlados, mas eram limitados diante da complexidade e imprevisibilidade do mundo real. As décadas de 1970 e 1980 foram marcadas por períodos de “inverno da IA”, nos quais o financiamento e o interesse científico diminuíram devido à frustração com os resultados obtidos. No entanto, a partir dos anos 2000, uma nova era começou a se delinear, impulsionada por três fatores principais: a explosão da geração de dados (big data), a melhoria dos algoritmos de aprendizado de máquina (machine learning – ML) e o desenvolvimento de hardware computacional especializado, como as Unidades de Processamento Gráfico (GPUs).

Essa nova fase da IA se consolidou com o surgimento de técnicas de aprendizado profundo (deep learning), que permitem a construção de redes neurais artificiais profundas capazes de aprender representações complexas diretamente a partir de grandes volumes de dados. O marco mais simbólico dessa transformação ocorreu em 2012, quando uma rede neural convolucional venceu a competição ImageNet, superando significativamente os métodos tradicionais de visão computacional. Desde então, a IA passou a dominar tarefas antes exclusivas da cognição humana, como reconhecimento de imagens e vozes, tradução automática, diagnósticos médicos, detecção de fraudes e até mesmo a geração de conteúdo textual, artístico e musical (GOODFELLOW; BENGIO; COURVILLE, 2016).





*Figura 1 - Campos da Inteligência Artificial*

Esse avanço foi acompanhado por um crescimento exponencial na demanda por capacidade computacional. O treinamento de modelos de IA modernos, especialmente os Modelos de Linguagem de Grande Escala (Large Language Models – LLMs), como o GPT, BERT e PaLM, exige infraestruturas computacionais colossais. Estima-se que o treinamento do GPT-3, por exemplo, tenha consumido mais de 1.287 MWh de energia elétrica, o equivalente ao consumo médio de 120 residências durante um ano inteiro (BENDER et al., 2021). Esses modelos utilizam bilhões de parâmetros e exigem semanas de processamento ininterrupto em clusters de servidores, equipados com milhares de GPUs de alto desempenho.

Além do treinamento, a fase de inferência — ou seja, a aplicação prática dos modelos em tempo real — também impõe desafios energéticos significativos. Plataformas de inteligência artificial que operam serviços de recomendação, assistentes virtuais, tradução simultânea e motores de busca processam milhões de requisições por segundo. Cada interação, por menor que seja, aciona redes neurais complexas que exigem capacidade computacional considerável. Como resultado, a operação contínua desses sistemas aumenta substancialmente o consumo de energia elétrica em escala global (ANTHONY; KORTHIKANTI; DRAMLIA, 2020).

Uma das métricas amplamente utilizadas para mensurar a eficiência energética de data centers é o Power Usage Effectiveness (PUE). Desenvolvida pelo Green Grid Consortium, essa métrica é calculada pela razão entre o consumo total de energia da instalação e a energia efetivamente usada nos equipamentos de TI.

$$PUE = \frac{\text{Energia total consumida pela instalação}}{\text{Energia consumida pelos equipamentos de TI}} \quad (1)$$

Um valor de PUE ideal se aproxima de 1,0, indicando alta eficiência energética – ou seja, toda a energia elétrica consumida pela instalação seria destinada exclusivamente aos equipamentos de TI, sem perdas em sistemas de refrigeração, iluminação, transformação e distribuição de energia. Na prática, entretanto, esse valor é raramente alcançado; a média global de PUE foi estimada em 1,59 em 2020, o que demonstra que uma parte significativa da energia ainda é direcionada para funções auxiliares (COELHO; FERREIRA, 2024)."

O Gráfico 1 apresenta a seguir a evolução da métrica PUE nos últimos anos, com base em dados de benchmarking internacional de data centers:




Gráfico 1 - Evolução da média global do PUE (Fonte: Coelho; Ferreira, 2024)

Além disso, o Gráfico 2 ilustra a distribuição típica do consumo de energia dentro de um data center moderno, evidenciando a parcela destinada a equipamentos de TI em comparação aos sistemas de suporte:




Gráfico 2 - Distribuição do consumo energético em data centers (Fonte: Coelho, Ferreira, 2024)

A compreensão e o monitoramento constante do PUE são fundamentais para a implementação de estratégias de eficiência energética nos centros de processamento de dados. A redução dessa métrica pode ser alcançada por meio de soluções como sistemas de resfriamento natural, uso de energia renovável, virtualização de servidores, e arquitetura computacional otimizada.

Além disso, o impacto ambiental do consumo de energia nos sistemas de IA não se limita à eletricidade utilizada nos processadores. O processo de resfriamento dos servidores consome grandes volumes de água em data centers tradicionais, especialmente aqueles que utilizam sistemas de refrigeração por evaporação ou torres de resfriamento (GOOGLE, 2023). Esse aspecto é frequentemente negligenciado nas análises energéticas, mas contribui significativamente para o uso de recursos naturais e pressiona ecossistemas em regiões com escassez hídrica.

A busca por maior eficiência energética também impulsiona o desenvolvimento de arquiteturas computacionais otimizadas, novos algoritmos de aprendizado com menor complexidade computacional e modelos pré-treinados de menor porte. Tais soluções visam reduzir o tempo de treinamento e o custo energético das inferências. Outra tendência observada é o uso de data centers em regiões com clima frio, que permitem resfriamento natural e, portanto, menor gasto energético (ANTHONY; KORTHIKANTI; DRAMLIA, 2020).

Considerando esses fatores, torna-se essencial dimensionar com precisão o consumo energético e os impactos associados aos sistemas de IA. Esse diagnóstico é crucial para fundamentar propostas de compensação energética com fontes renováveis, como a energia solar fotovoltaica, e viabilizar um avanço tecnológico comprometido com a sustentabilidade.

Essa infraestrutura computacional está concentrada em grandes data centers distribuídos ao redor do mundo. Essas instalações operam continuamente e consomem energia para processamento, refrigeração, controle de umidade e redundância operacional. A Agência Internacional de Energia (IEA, 2023) estima que, até 2030, os data centers e redes de telecomunicações podem representar até 8% da demanda global de eletricidade. Boa parte dessa energia ainda é proveniente de fontes fósseis, como carvão, petróleo e gás natural, agravando a emissão de gases de efeito estufa (GEE) e contribuindo diretamente para o aquecimento global e a intensificação da crise climática.



*Figura 2 – Representação esquemática de um Data Center utilizado para treinamento de modelos de IA.*

Nesse contexto, a relação entre o progresso tecnológico da IA e a sustentabilidade ambiental torna-se uma questão urgente e estratégica. A eficiência energética e o uso de fontes renováveis de energia são elementos-chave para mitigar os impactos ambientais associados à digitalização da sociedade. É necessário encontrar soluções que viabilizem o desenvolvimento da IA sem comprometer os compromissos internacionais de redução de emissões de carbono, como os estabelecidos no Acordo de Paris.

Nesse cenário de crescente demanda energética, uma alternativa viável e sustentável é o uso da energia solar fotovoltaica como forma de compensação e suprimento

energético para sistemas de inteligência artificial. A energia solar apresenta inúmeras vantagens: é renovável, abundante, silenciosa, não emite poluentes atmosféricos durante sua operação e possui custos de instalação cada vez mais acessíveis. A adoção de sistemas fotovoltaicos em data centers e instalações computacionais representa uma estratégia promissora para reduzir a pegada de carbono da IA e aumentar a resiliência energética dessas infraestruturas (JACOBSON et al., 2022).

Dessa forma, este trabalho tem como objetivo geral quantificar o impacto ambiental associado ao consumo de energia por sistemas de inteligência artificial, considerando os processos de treinamento e inferência de modelos de grande escala. A partir dessa análise, busca-se avaliar a viabilidade técnica, ambiental e econômica da compensação desse consumo por meio da implementação de sistemas de geração de energia solar fotovoltaica.

Como objetivos específicos, propõe-se:

- Levantar dados atualizados sobre o consumo energético de modelos de IA de grande escala;
- Estimar as emissões de CO<sub>2</sub> associadas a esse consumo, com base em diferentes matrizes energéticas;
- Dimensionar um sistema fotovoltaico capaz de compensar esse consumo;
- Analisar a viabilidade econômica da solução proposta, considerando o custo-benefício e o tempo de retorno do investimento;
- Discutir os benefícios ambientais decorrentes da substituição ou compensação da energia convencional por energia solar.

Este estudo pretende contribuir para o debate multidisciplinar sobre os impactos ambientais das tecnologias emergentes, oferecendo subsídios técnicos e científicos para a formulação de políticas sustentáveis de desenvolvimento tecnológico. Ao integrar os campos da engenharia de energias renováveis, ciência da computação e meio ambiente, o presente trabalho propõe um caminho para a conciliação entre inovação e sustentabilidade, refletindo os desafios e as oportunidades da transição energética em curso.

## **2 FUNDAMENTAÇÃO TEÓRICA**

A fundamentação teórica deste trabalho visa contextualizar e aprofundar os conceitos-chave relacionados à Inteligência Artificial, seu consumo energético, os impactos

ambientais associados e a viabilidade da energia solar fotovoltaica como alternativa sustentável. Com base em estudos recentes e fontes acadêmicas confiáveis, esta seção estabelece os fundamentos para a análise crítica desenvolvida nos capítulos seguintes.

## **2.1 Inteligência Artificial e Aprendizado de Máquina**

A Inteligência Artificial (IA) refere-se à capacidade de sistemas computacionais em realizar tarefas que, tradicionalmente, exigiriam inteligência humana, como raciocínio, percepção, tomada de decisão e aprendizado. O campo teve início na década de 1950, com os primeiros estudos de Alan Turing e John McCarthy, e evoluiu significativamente com o avanço da computação e do armazenamento de dados (RUSSELL; NORVIG, 2021).

Um dos subcampos mais relevantes da IA atual é o aprendizado de máquina (machine learning), que permite que algoritmos identifiquem padrões e tomem decisões baseadas em dados. Dentro deste campo, destaca-se o aprendizado profundo (deep learning), caracterizado pelo uso de redes neurais artificiais com múltiplas camadas, permitindo um desempenho elevado em tarefas complexas como reconhecimento de voz, tradução automática e geração de texto (GOODFELLOW; BENGIO; COURVILLE, 2016).

Os modelos de linguagem de grande escala (LLMs), como o GPT-4 (OpenAI) e o PaLM (Google), representam o ápice dessa evolução, sendo treinados com trilhões de parâmetros e bases de dados massivas.

Esse treinamento, no entanto, exige uma enorme capacidade computacional, o que tem implicações diretas no consumo de energia e nas emissões de carbono.

## **2.2 Consumo Energético dos Sistemas de IA**

O desenvolvimento de sistemas de IA em larga escala está diretamente associado ao uso intensivo de data centers — estruturas físicas compostas por milhares de servidores interconectados, responsáveis pelo processamento, armazenamento e transferência de dados. Segundo a International Energy Agency (IEA, 2023), os data centers já consomem aproximadamente 1,5% de toda a eletricidade gerada globalmente, e essa participação tende a crescer com a ampliação do uso de IA generativa.

O consumo energético ocorre em duas etapas principais:

- Treinamento dos modelos, que pode durar semanas ou meses, utilizando múltiplas GPUs e unidades de processamento de alto desempenho (TPUs), gerando consumo energético na ordem de centenas de megawatts-hora (MWh);
- Inferência (uso cotidiano dos modelos), que ocorre a cada vez que um usuário interage com um sistema de IA. Com milhões de requisições diárias, o custo energético do uso contínuo pode superar o do treinamento ao longo do tempo (ANTHONY; KORTHIKANTI; DRAMLIA, 2020).

De acordo com Strubell et al. (2019), o treinamento de um modelo como o BERT, da Google, em uma versão otimizada, resultou na emissão de cerca de 1,5 tonelada de CO<sub>2</sub>, considerando uma matriz elétrica média dos Estados Unidos. Para modelos mais robustos, como o GPT-3, esse número pode ultrapassar 500 toneladas de CO<sub>2</sub> durante a fase de treinamento (PATTERSON et al., 2021).

### 2.3 Impactos Ambientais da Geração de Energia Elétrica

O consumo energético, por si só, não seria um problema ambiental se toda a energia utilizada fosse proveniente de fontes renováveis. No entanto, a realidade é que boa parte da eletricidade mundial ainda é gerada a partir de combustíveis fósseis, como carvão, petróleo e gás natural. Essas fontes emitem grandes quantidades de gases de efeito estufa (GEE), como o dióxido de carbono (CO<sub>2</sub>), responsáveis pelo aquecimento global e pelas mudanças climáticas (IPCC, 2021).

A emissão de CO<sub>2</sub> por kWh varia conforme a matriz elétrica de cada país. Por exemplo:

- **Alemanha** (com alta participação de carvão): cerca de 400 a 600 gCO<sub>2</sub>/kWh;
- **Brasil** (com grande uso de hidrelétricas): cerca de 40 a 60 gCO<sub>2</sub>/kWh (ANEEL, 2023).

### 2.4 Energia Solar Fotovoltaica como Solução Sustentável

A energia solar fotovoltaica converte a radiação solar em eletricidade por meio de células semicondutoras. Essa fonte de energia é considerada limpa, renovável, de baixo impacto ambiental e com potencial de geração distribuída. Além disso, tem apresentado significativa

redução de custos na última década, tornando-se uma alternativa competitiva frente às fontes tradicionais (IEA, 2023).

Segundo dados da Agência Internacional de Energia Renovável (IRENA, 2023), o custo médio global da geração fotovoltaica caiu mais de 80% desde 2010. No Brasil, o avanço da legislação, aliado à abundância de radiação solar e incentivos fiscais, fez com que a capacidade instalada ultrapassasse os 37 GW em 2024, posicionando o país entre os dez maiores mercados solares do mundo (ABSOLAR, 2024).

A adoção da energia solar no contexto da IA pode ocorrer de diversas formas:

- Instalação de usinas solares próprias em data centers ou suas proximidades;
- Parcerias com fornecedores de energia renovável;
- Compensação energética via créditos de energia em sistemas de geração distribuída.

Além da redução de emissões, a geração solar proporciona redução de custos operacionais, independência energética e valorização da imagem corporativa por meio da responsabilidade ambiental.

### **3 RESULTADOS E DISCUSSÃO**

#### **3.1 Estimativa de Consumo Energético e Emissões de CO<sub>2</sub> para Modelos de IA**

Estudos recentes indicam que o consumo energético para treinamento de modelos de linguagem de grande escala varia conforme o modelo, infraestrutura e frequência de inferência (STRUBELL et al., 2019; PATTERSON et al., 2021). Um levantamento da Universidade de Massachusetts apontou que o treinamento do modelo GPT-3 consumiu cerca de **1.287 MWh** (PATTERSON et al., 2021).

Considerando que modelos similares são periodicamente atualizados (retraining) e que a inferência contínua em produção pode consumir entre 1 a 10 vezes o consumo do treinamento, adotou-se o seguinte cenário por representar um uso realista de LLMs em operação contínua para este estudo:



<b>Etapa</b>	<b>Consumo Estimado (MWh)</b>
Treinamento (único)	1.287
Inferência (anual)	2.000
<b>Total anual</b>	<b>3.287</b>

As emissões de CO<sub>2</sub> associadas ao consumo energético dependem da matriz elétrica local. Consideraram-se três cenários com fatores de emissão médios (IEA, 2023; GHG PROTOCOL, 2023):

<b>Matriz Elétrica</b>	<b>Fator de Emissão (kg CO<sub>2</sub>/kWh)</b>	<b>Emissão Total (t CO<sub>2</sub>/ano)</b>
EUA (média)	0,40	1.314,8
China	0,70	2.300,9
Brasil (limpa)	0,10	328,7

Mesmo com matriz relativamente limpa, como a brasileira, a operação desses sistemas gera emissões relevantes. Países com matrizes mais poluentes apresentam impactos ambientais muito superiores.

### 3.2 Dimensionamento do Sistema Fotovoltaico Compensatório

Para compensar o consumo anual estimado de **3.287 MWh**, projetou-se um sistema fotovoltaico considerando condições médias do Nordeste brasileiro, com irradiação solar média diária de 5,0 kWh/m<sup>2</sup>, e fator de desempenho (performance ratio) de 0,75.

A potência instalada necessária foi calculada pela fórmula:

$$KW_p = \frac{E}{(H * 365 * PR)} \quad (2)$$

Onde:

- **E**=3.287.000 kWh (energia anual a ser compensada)
- **H**=5,0 kWh/m<sup>2</sup>/dia (irradiância média diária)
- **PR**=0,75 (performance ratio)

Substituindo os valores:

$$\text{KWp} = \frac{3.287.000}{5 \times 365 \times 0,75} \approx 2.400 \text{ kWp} \quad (3)$$

As principais características do sistema proposto são:

Potência instalada: **2.400 kWp (2,4 MWp)**

Área ocupada: aproximadamente **20.000 m²**

Módulos fotovoltaicos (550 Wp): cerca de **4.364 unidades**

### 3.3 Viabilidade Econômica

A viabilidade econômica de sistemas fotovoltaicos é um dos fatores determinantes para sua adoção em larga escala, especialmente em empreendimentos com alto consumo energético. Nesta seção, apresenta-se a análise do custo total de implantação, a economia anual estimada, o tempo de retorno do investimento (payback) e o retorno sobre o investimento (ROI), considerando uma vida útil média de 25 anos para o sistema.

#### 3.3.1 Custo de Implantação

O custo total do sistema foi calculado com base em uma capacidade instalada de 2.400.000 Wp, ao custo médio de R\$ 4,20/Wp, valor comumente praticado para sistemas fotovoltaicos de médio a grande porte, englobando aquisição, instalação e comissionamento. O custo total do sistema pode ser obtido conforme a Equação 4:

$$\text{Custo total} = 2.400.000 \times 4,20 = \text{R\$ } 10.080.000,00 \quad (4)$$

Esse é o valor total do investimento necessário para a implantação do sistema fotovoltaico conectado à rede.

#### 3.3.2 Economia Anual Estimada

Considerando um consumo anual de 3.287.000 kWh e uma taxa de compensação de 80%, a economia anual projetada pelo sistema pode ser expressa pela Equação 5:

$$\text{Economia anual} = 3.287.000 \times 0,80 = 2.629.600 \text{ kWh} \quad (5)$$

Assumindo uma tarifa média de energia de R\$ 1,00/kWh, a economia anual direta é estimada em R\$ 2.629.600,00. Essa economia representa a redução nos gastos anuais com energia elétrica.

### 3.3.2.1 Análise de Sensibilidade da Rentabilidade do Sistema Fotovoltaico

Na análise da viabilidade econômica do sistema fotovoltaico proposto para compensar o consumo energético de modelos de inteligência artificial, identificaram-se parâmetros que influenciam significativamente o retorno sobre o investimento (ROI). A seguir, destacam-se os principais fatores que podem impactar esse indicador ao longo da vida útil do sistema:

- Variação Tarifária de Energia Elétrica: A tarifa de energia praticada pelas concessionárias é um dos principais determinantes da economia gerada pelo sistema fotovoltaico. A adoção de um cenário tarifário mais elevado potencializa os benefícios financeiros da geração própria, reduzindo o tempo de retorno do investimento e aumentando o ROI. Por outro lado, uma redução significativa na tarifa pode tornar o sistema menos atrativo economicamente. É importante destacar que a instabilidade regulatória e eventuais mudanças nas regras de compensação de energia (como as introduzidas pelo Marco Legal da Geração Distribuída – Lei nº 14.300/2022) também afetam esse parâmetro.

- Inflação e Taxa de Atualização: A inflação impacta diretamente o valor real das economias projetadas ao longo dos anos, principalmente quando há descompasso entre a correção da tarifa de energia e o índice inflacionário. Além disso, a escolha da taxa de desconto utilizada nas análises de fluxo de caixa descontado influencia fortemente o valor presente líquido (VPL) e o ROI. Taxas de atualização mais altas tornam o investimento menos atrativo ao reduzir o valor presente dos benefícios futuros.

- Custo Inicial e Depreciação dos Equipamentos: Embora o sistema fotovoltaico apresente baixos custos operacionais, o investimento inicial elevado é um fator sensível. A eventual queda nos preços de painéis e inversores poderia melhorar o ROI em projetos futuros. Além disso, a depreciação acelerada dos componentes — devido a fatores como envelhecimento prematuro ou falhas técnicas — pode reduzir a geração de energia ao longo do tempo e, consequentemente, os ganhos econômicos projetados. A depreciação também impacta

a análise contábil do projeto, podendo afetar decisões empresariais sobre adoção em larga escala.

- Fatores Climáticos e Degradação da Eficiência: A irradiância solar anual e as condições climáticas da região onde o sistema é instalado também afetam diretamente a produção de energia. Uma menor incidência solar ou a degradação acelerada da eficiência dos módulos ao longo do tempo compromete a geração esperada, impactando o retorno financeiro. Assim, variações inesperadas nesses fatores devem ser consideradas em análises de risco.

Dessa forma, conclui-se que a sensibilidade do ROI a essas variáveis reforça a importância de análises econômicas robustas, com simulações que considerem diferentes cenários macroeconômicos, técnicos e regulatórios. Isso permite maior segurança na tomada de decisão quanto à adoção de sistemas fotovoltaicos como solução sustentável para compensação energética de tecnologias intensivas em computação, como os modelos de linguagem de grande escala (LLMs).

### **3.3.2.2 Viabilidade de Replicação em Data Centers com Limitação de Espaço Físico**

Embora o sistema fotovoltaico proposto tenha se mostrado viável do ponto de vista energético e ambiental para compensação parcial do consumo associado ao uso de modelos de inteligência artificial, sua replicação direta em data centers existentes pode ser limitada pela disponibilidade de espaço físico para a instalação dos módulos solares.

Em muitos casos, especialmente em ambientes urbanos ou em data centers consolidados, não há área suficiente nos telhados ou terrenos adjacentes para acomodar uma planta fotovoltaica com a capacidade necessária. Nesses contextos, algumas alternativas viáveis para a replicação do modelo incluem:

- Contratação de Energia Solar por Geração Remota (GD remota): A geração compartilhada prevista pela Lei nº 14.300/2022 permite que consumidores, como data centers, utilizem créditos de energia gerados por usinas fotovoltaicas instaladas em outros locais, dentro da mesma área de concessão da distribuidora. Dessa forma, o modelo de compensação energética pode ser replicado sem a necessidade de instalação física no próprio local de consumo.

- Parcerias com Fazendas Solares e Consórcios Energéticos: Data centers podem firmar acordos com usinas solares de médio ou grande porte por meio de contratos de longo prazo (PPA – Power Purchase Agreements), garantindo previsibilidade de custos e

sustentabilidade energética. Essa abordagem viabiliza a compensação de grandes volumes de consumo, inclusive com escalabilidade para crescimento futuro da operação.

- Aquisição de Créditos de Energia ou Certificados de Energia Renovável (I-RECs): Quando a instalação física ou a contratação direta não são possíveis, outra alternativa é a aquisição de certificados de energia renovável (RECs ou I-RECs), que comprovam que determinada quantidade de energia consumida foi compensada por geração limpa. Embora não configure compensação direta na fatura, contribui para a neutralização das emissões associadas ao consumo energético.

- Integração com Infraestruturas Compartilhadas ou Híbridas: Outra possibilidade é a implantação de sistemas fotovoltaicos em locais estratégicos compartilhados por múltiplas unidades consumidoras — como galpões logísticos, edifícios corporativos ou áreas industriais — criando uma infraestrutura híbrida com múltiplos beneficiários.

Portanto, mesmo diante da limitação física para instalação local, o modelo proposto neste estudo pode ser adaptado por meio de soluções técnicas, contratuais e regulatórias já disponíveis no mercado nacional. Tais estratégias mantêm o objetivo principal da proposta: mitigar os impactos ambientais do consumo energético de modelos de inteligência artificial por meio do uso de fontes renováveis, em especial a solar fotovoltaica.

### **3.3.2.3 Considerações Sobre Armazenamento de Energia no Contexto da Compensação Fotovoltaica**

Embora o presente estudo tenha adotado a compensação energética por meio da injeção direta de energia solar fotovoltaica na rede elétrica, sem considerar o uso de sistemas de armazenamento, é relevante discutir as implicações técnicas, econômicas e ambientais da adoção de baterias em projetos similares.

O armazenamento de energia, especialmente por meio de baterias de íon-lítio, pode oferecer benefícios como maior autonomia energética, redução da dependência da rede em horários de pico e aumento da autossuficiência em locais com instabilidade elétrica. No entanto, esses sistemas ainda apresentam custo elevado, o que compromete diretamente o retorno sobre o investimento (ROI) e o valor presente líquido (VPL) do projeto.

Além disso, a análise ambiental da produção, uso e descarte de baterias deve ser cuidadosamente considerada, especialmente quando o objetivo é a sustentabilidade do ciclo energético. A introdução de armazenamento também exigiria uma reformulação no

dimensionamento do sistema e na lógica de operação, com a inclusão de controladores específicos e manutenção mais complexa.

Dessa forma, optou-se por não incluir o armazenamento neste estudo, priorizando a viabilidade prática e a compatibilidade com o modelo regulatório brasileiro vigente (Lei nº 14.300/2022), que permite a compensação remota por meio da injeção na rede. No entanto, em contextos específicos — como regiões isoladas, sistemas híbridos ou aplicações críticas — o uso de baterias pode ser tecnicamente justificável e merece investigação futura.

### 3.3.3 Tempo de Retorno do Investimento (Payback)

O tempo de retorno do investimento, ou payback simples, é obtido pela razão entre o investimento inicial e a economia anual, conforme apresentado na Equação 6:

$$\text{Payback} = \frac{\text{Investimento}}{\text{Economia anual}} = \frac{10.080.000}{2.629.600} \approx 3,83 \text{ anos} \quad (6)$$

Assim, o sistema terá o retorno do capital investido em aproximadamente 3 anos e 10 meses de operação.

### 3.3.4 Retorno sobre o Investimento (ROI)

Considerando uma vida útil de 25 anos para o sistema fotovoltaico, o retorno sobre o investimento (ROI) pode ser determinado com base na Equação 7:

$$\text{ROI} = \frac{\text{Lucro líquido acumulado}}{\text{Investimento inicial}} \times 100 \quad (7)$$

Para o caso em estudo, considera-se um retorno anual estimado de R\$ 2.629.600,00 ao longo de uma vida útil de 25 anos, o que resulta em um retorno total de:

$$\text{Retorno total} = 2.629.600 \times 25 = \text{R\$ } 65.740.000,00 \quad (8)$$

Este valor indica que, ao longo dos 25 anos de operação, o sistema retorna mais de 5 vezes o capital investido, reforçando sua atratividade econômica.

O investimento inicial necessário para a implantação do sistema é de R\$ 10.080.000,00. Assim, o lucro líquido acumulado ao longo da vida útil é dado por:

$$\text{Lucro líquido acumulado} = 65.740.000 - 10.080.000 = \text{R\$ } 55.660.000,00 \quad (9)$$

Substituindo os valores na equação do ROI, tem-se:

$$\text{ROI} = \frac{55.660.000}{10.080.000} \times 100 \approx 552,18\% \quad (10)$$

Com base nos dados apresentados, verifica-se que o sistema fotovoltaico proposto apresenta viabilidade econômica elevada, com tempo de retorno inferior a quatro anos e um ROI superior a 500%. Esses indicadores reforçam o papel estratégico das fontes renováveis na redução de custos energéticos em longo prazo, além de contribuírem significativamente para a sustentabilidade ambiental da operação.

### 3.4 Benefícios Ambientais e Estratégicos da Compensação com Energia Solar

A adoção de sistemas fotovoltaicos para compensação do consumo energético, especialmente em operações intensivas em computação, como data centers que suportam modelos de linguagem de grande escala (LLMs), traz benefícios ambientais e estratégicos significativos.

#### 3.4.1 Benefícios Ambientais:

O principal benefício ambiental está na redução direta das emissões de gases de efeito estufa (GEE) associadas à geração de eletricidade a partir de fontes fósseis. Ao substituir parte do consumo energético por energia solar fotovoltaica, o sistema contribui para a mitigação das mudanças climáticas, alinhando-se às metas globais de neutralidade de carbono (IPCC, 2021). Além disso, a utilização de energia renovável reduz a dependência de recursos naturais finitos e minimiza os impactos ambientais causados pela extração e transporte de combustíveis fósseis (SILVA; PEREIRA, 2020).

### 3.4.2 Benefícios Estratégicos:

Do ponto de vista estratégico, a implementação de sistemas fotovoltaicos fortalece a imagem institucional das organizações, evidenciando compromisso com a sustentabilidade e responsabilidade socioambiental (MARTINS; ALMEIDA, 2019). Tal posicionamento pode resultar em vantagens competitivas, atração de investidores e melhor relacionamento com consumidores e órgãos reguladores (COSTA; RODRIGUES, 2021).

Além disso, a energia solar proporciona maior previsibilidade e potencial redução dos custos operacionais a longo prazo, dado que, após o investimento inicial, apresenta custo marginal próximo de zero, protegendo contra variações tarifárias (FARIA et al., 2018).

Podemos citar exemplos reais no setor de tecnologia com grandes empresas globais que incorporaram energia solar em suas estratégias para tornar suas operações mais sustentáveis:

- Amazon: A empresa investiu em diversos projetos solares globais, tornando-se em 2021 o maior comprador corporativo de energia renovável do mundo (AMAZON, 2022). Essa iniciativa faz parte do compromisso da Amazon com a neutralidade de carbono até 2040, reduzindo a pegada de carbono de seus data centers e operações logísticas.

- Google: A Google alcançou a meta de operar com energia 100% livre de carbono em todos os seus data centers e escritórios desde 2017 (GOOGLE, 2023). A empresa investe em contratos de compra de energia renovável (PPA) para garantir fornecimento sustentável e contínuo.

- Equinix: A empresa, especializada em data centers, adota sistemas fotovoltaicos em algumas instalações e certifica a compra de energia renovável para compensar seu consumo (EQUINIX, 2022). Além disso, promove iniciativas para eficiência energética, reduzindo custos e emissões.

Esses exemplos evidenciam que o investimento em energia solar é uma estratégia consolidada para mitigar impactos ambientais e garantir sustentabilidade em operações intensivas em computação, como as que utilizam LLMs.

## 3.5 Discussão Geral

A análise evidencia que modelos de inteligência artificial de grande escala demandam consumo energético elevado, impactando diretamente o meio ambiente. A



implantação de sistemas solares fotovoltaicos para compensação desse consumo configura-se como uma alternativa tecnicamente viável e financeiramente atrativa.

Além dos benefícios ambientais, a geração própria promove independência energética e previsibilidade de custos, essenciais para a sustentabilidade operacional dessas tecnologias emergentes.

Assim, recomenda-se a integração de energias renováveis nos processos de desenvolvimento e operação de sistemas de IA fomentando um ciclo virtuoso de inovação tecnológica e sustentabilidade ambiental.

## **4. CONCLUSÃO**

### **4.1 Avaliação geral do impacto ambiental**

O consumo energético dos sistemas de inteligência artificial (IA), sobretudo dos modelos de linguagem de grande escala (LLMs), tem se revelado uma questão ambiental de crescente relevância. O desenvolvimento acelerado dessas tecnologias implica um aumento exponencial da demanda por recursos computacionais, resultando em elevado consumo de energia elétrica durante as etapas de treinamento e inferência dos modelos (PATTERSON et al., 2021). Estima-se que o consumo anual para operar um modelo como o GPT-3 possa ultrapassar 3.000 MWh, o que se traduz em emissões significativas de gases de efeito estufa, especialmente em países com matriz energética baseada em combustíveis fósseis (STRUBELL et al., 2019). Mesmo em regiões com matriz limpa, como o Brasil, o consumo expressivo ainda representa um impacto ambiental relevante que necessita de atenção e mitigação.

### **4.2 Viabilidade da solução proposta**

A compensação desse consumo energético por meio da geração de energia solar fotovoltaica demonstra-se uma alternativa tecnicamente exequível e economicamente vantajosa. O dimensionamento realizado para um sistema de aproximadamente 2,4 MWp, considerando as condições típicas de irradiação solar no Nordeste brasileiro, mostra que é possível neutralizar integralmente a demanda energética dos modelos analisados. Além da

contribuição ambiental, o sistema demonstrou desempenho financeiro atrativo, com payback estimado inferior a cinco anos e vida útil prolongada, o que reforça a viabilidade da solução em um contexto de sustentabilidade e economia (IEA, 2023). A adoção dessa tecnologia pode ainda promover maior independência energética para os centros de processamento de dados, reduzindo vulnerabilidades frente a variações tarifárias e oscilações na oferta da rede elétrica convencional.

### **4.3 Limitações e sugestões para estudos futuros**

Embora os resultados obtidos sejam promissores, esta pesquisa apresenta algumas limitações importantes. A dependência de dados secundários e estimativas sobre o consumo energético dos sistemas de IA compromete a precisão das análises, uma vez que as empresas tecnológicas geralmente não divulgam detalhes específicos sobre o consumo de seus data centers. Ademais, a análise concentrou-se exclusivamente na compensação por meio da energia solar fotovoltaica, não contemplando outras fontes renováveis que poderiam compor uma matriz energética mais diversificada e resiliente, como a eólica e a biomassa.

Dessa forma, recomenda-se que futuros estudos ampliem a investigação para uma análise do ciclo de vida completo dos sistemas de IA englobando desde a fabricação dos equipamentos até o descarte final, de modo a avaliar o impacto ambiental total. É igualmente relevante promover comparações entre diferentes fontes de energia renovável para compensação, bem como investigar estratégias para a otimização do consumo energético dos modelos, incluindo avanços em hardware e algoritmos mais eficientes. A avaliação das políticas de compensação de carbono em empresas de tecnologia que utilizam IA em larga escala também pode oferecer insights para práticas corporativas sustentáveis.

Adicionalmente, sugere-se a inclusão de estudos que analisem o consumo de água nos sistemas de resfriamento de data centers, uma vez que essa prática pode representar impacto ambiental significativo, especialmente em regiões com escassez hídrica. Por fim, o desenvolvimento de modelos descentralizados de geração energética, especialmente para data centers localizados em áreas remotas ou isoladas, apresenta-se como um campo promissor para contribuir com a redução dos impactos ambientais associados à expansão da inteligência artificial.

#### 4.4 Barreiras Políticas e Regulatórias

A ampliação da compensação energética com sistemas fotovoltaicos, especialmente para aplicações de alta demanda como data centers voltados à operação de modelos de inteligência artificial, enfrenta diversas barreiras de ordem política e regulatória. Tais obstáculos impactam diretamente a viabilidade econômica e a escalabilidade do modelo proposto, conforme detalhado a seguir:

- Mudanças nas regras de compensação de energia elétrica:

Com a Lei nº 14.300/2022, conhecida como Marco Legal da Geração Distribuída, o modelo de compensação da energia excedente injetada na rede sofreu alterações significativas. A norma prevê um regime de transição no qual, progressivamente, os créditos recebidos pelos consumidores-geradores serão reduzidos. Essa mudança pode afetar a rentabilidade de novos sistemas fotovoltaicos, especialmente para grandes consumidores como data centers, que dependem de estabilidade econômica para justificar investimentos em infraestrutura.

- Limitações na contratação de geração distribuída remota:

Embora exista a possibilidade de geração compartilhada ou remota, as restrições quanto à distância entre os pontos de geração e consumo, além da exigência de titularidade comum ou vínculo jurídico entre as unidades, limitam o potencial de adoção por grandes corporações. Essa barreira é especialmente crítica quando não há espaço físico disponível para instalação de sistemas solares localmente.

- Burocracia e morosidade nos processos de licenciamento:

A instalação de sistemas de energia solar, mesmo de pequeno porte, ainda enfrenta processos burocráticos lentos e complexos, relacionados à conexão à rede, licenciamento ambiental e aprovação junto às distribuidoras. Em projetos de maior escala, essas etapas podem aumentar significativamente os custos e prazos de implementação, tornando o investimento menos atrativo.

- Insegurança jurídica e instabilidade regulatória

A ausência de garantias de estabilidade das regras regulatórias e o histórico de alterações repentinas no marco legal da geração distribuída contribuem para um ambiente de incerteza. Isso gera desconfiança por parte de investidores e empresas interessadas em adotar soluções energéticas sustentáveis de longo prazo.

- Tributação sobre a energia gerada

Alguns estados brasileiros ainda aplicam ICMS sobre a energia elétrica gerada e autoconsumida, o que reduz os ganhos econômicos da compensação energética. A cobrança de tributos sobre a energia injetada ou compensada, mesmo quando a geração é feita no próprio local de consumo, compromete a viabilidade financeira de projetos fotovoltaicos, em especial no modelo de geração distribuída.

- Ausência de políticas específicas para o setor de data centers

Apesar de representarem uma das maiores cargas energéticas entre as operações corporativas, os data centers ainda não são contemplados por políticas públicas específicas que incentivem sua transição para fontes renováveis. A falta de linhas de crédito dedicadas, incentivos fiscais ou programas de certificação ambiental limita o desenvolvimento de soluções sustentáveis nesse setor estratégico para a infraestrutura digital do país.

#### **4.4 Considerações finais**

A inteligência artificial constitui-se como uma das tecnologias mais impactantes e transformadoras do século XXI, com potencial para revolucionar múltiplos setores da sociedade. Contudo, é imprescindível que seu avanço seja acompanhado por uma abordagem responsável, pautada na sustentabilidade ambiental. O presente estudo demonstrou que é plenamente possível conciliar o desenvolvimento tecnológico com a mitigação dos impactos ambientais por meio do uso da energia solar fotovoltaica.

Dessa forma, a compensação energética proposta com o uso de sistemas fotovoltaicos representa uma medida relevante na direção da sustentabilidade computacional, especialmente ao mitigar parte das emissões de gases de efeito estufa associadas ao consumo elétrico de modelos de linguagem de grande escala. No entanto, a análise indica que essa abordagem não é suficiente para eliminar completamente a pegada de carbono desses sistemas, uma vez que não contempla as emissões indiretas relacionadas à fabricação, transporte e descarte de equipamentos, nem o impacto do consumo energético fora do horário de geração solar. Assim, para que a neutralidade de carbono seja plenamente alcançada, é necessário complementar a compensação fotovoltaica com estratégias adicionais, como a melhoria da eficiência computacional, o uso de data centers abastecidos com energia 100% renovável e a aquisição de créditos de carbono certificados.

A implantação de sistemas fotovoltaicos para compensar o consumo energético dos sistemas de IA não só contribui para a redução das emissões de gases de efeito estufa, mas

também reforça o compromisso ambiental e social de instituições e empresas, melhora a resiliência energética e promove a diversificação da matriz elétrica. Assim, as práticas propostas neste trabalho podem servir de referência para empresas, instituições acadêmicas e órgãos governamentais que busquem alinhar inovação tecnológica com sustentabilidade.

Recomenda-se a adoção de métricas como o PUE para o monitoramento contínuo da eficiência energética dos data centers, de modo a identificar oportunidades de otimização e reduzir a demanda por geração adicional, renovável ou não.

Para assegurar uma inteligência artificial verdadeiramente sustentável, é fundamental que a academia, o setor produtivo e a sociedade civil estabeleçam parcerias efetivas, fomentando pesquisas, políticas e investimentos que potencializem o uso de energias renováveis e a eficiência energética dos sistemas computacionais. Dessa forma, será possível preservar os recursos naturais e garantir que os benefícios da IA sejam usufruídos pelas gerações presentes e futuras.

## 5. REFERÊNCIAS

ABSOLAR – ASSOCIAÇÃO BRASILEIRA DE ENERGIA SOLAR FOTOVOLTAICA. Dados do Setor. 2024. Disponível em: <https://www.absolar.org.br>. Acesso em: 21 jun. 2025.

AMAZON. Sustainability Report 2022. Disponível em: <https://sustainability.aboutamazon.com/>. Acesso em: 20 jul. 2025.

ANEEL – AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA. Fatores de emissão de CO<sub>2</sub> por fonte de geração elétrica no Brasil. Brasília: ANEEL, 2023.

ANTHONY, L.; KORTHIKANTI, V.; DRAMLIA, K. The carbon footprint of machine learning training will plateau, then shrink. IEEE Spectrum, 2020. Disponível em: <https://spectrum.ieee.org/the-carbon-footprint-of-machine-learning-training-will-plateau-then-shrink>. Acesso em: 10 jul. 2025.

ANTHONY, L.; KORTHIKANTI, V.; DRAMLIA, P. The carbon impact of artificial intelligence. Microsoft Research, 2020. Disponível em: <https://www.microsoft.com/en-us/research/project/the-carbon-impact-of-ai/>. Acesso em: 21 jun. 2025.

BENDER, E. M. et al. On the dangers of stochastic parrots: can language models be too big? In: Proceedings of the 2021 ACM Conference on Fairness, Accountability, and Transparency, 2021. p. 610–623. DOI: <https://doi.org/10.1145/3442188.3445922>. Disponível em: <https://dl.acm.org/doi/10.1145/3442188.3445922>. Acesso em: 10 jul. 2025.

BRASIL. Agência Nacional de Energia Elétrica (ANEEL). Resolução Normativa nº 1.059/2023. Dispõe sobre o Sistema de Compensação de Energia Elétrica – SCEE. Brasília: ANEEL, 2023.

COELHO, D.; FERREIRA, M. O consumo energético dos data centers e a eficiência dos sistemas de refrigeração: estudo de caso sobre o uso da métrica PUE. Revista Brasileira de Ecogestão, v. 11, n. 29, p. 214–229, 2024. Disponível em: <https://revista.ecogestaobrasil.net/v11n29/v11n29a14a.html>. Acesso em: 14 jul. 2025.

COELHO, R. F.; FERREIRA, M. A. Avaliação da eficiência energética em data centers e o indicador PUE: uma revisão sistemática. *Revista Brasileira de Ecogestão*, v. 11, n. 29, p. 259–275, 2024. Disponível em: <https://revista.ecogestaobrasil.net/v11n29/v11n29a14a.html>. Acesso em: 10 jul. 2025.

COSTA, L. M.; RODRIGUES, A. F. Sustentabilidade empresarial: impactos e estratégias competitivas. *Revista de Gestão Ambiental*, v. 12, n. 3, p. 45-62, 2021.

CRESESB – CENTRO DE REFERÊNCIA PARA ENERGIA SOLAR E EÓLICA SÉRGIO DE SALVO BRITO. Manual de engenharia para sistemas fotovoltaicos. Rio de Janeiro: CEPEL, 2014.

EQUINIX. Global Sustainability Report 2022. Disponível em: <https://investor.equinix.com/sustainability>. Acesso em: 20 jul. 2025.

FARIA, J. P. et al. Avaliação econômica de sistemas fotovoltaicos conectados à rede. *Revista Brasileira de Energia Renovável*, v. 7, n. 2, p. 123-134, 2018.

FRANÇA, Vitor. Desafios energéticos em treinamento de modelos de inteligência artificial. 2024. Trabalho de Conclusão de Curso (Graduação em Ciência da Computação) – Escola Politécnica, Ponticifia Universidade Católica de Goiás, Goiânia, 2024. Disponível em: <https://repositorio.pucgoias.edu.br/jspui/handle/123456789/7901>. Acesso em: 14 jul. 2025.

GHG PROTOCOL. Greenhouse Gas Protocol Initiative: a multi-stakeholder partnership for standardized GHG accounting. Disponível em: <https://ghgprotocol.org>. Acesso em: 01 jul. 2025.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. Deep learning. Cambridge: MIT Press, 2016.

GOOGLE. Data centers and water. Google Sustainability, 2023. Disponível em: <https://sustainability.google/commitments/data-centers-water/>. Acesso em: 10 jul. 2025.

GOOGLE. Environmental Report 2023. Disponível em: <https://sustainability.google/reports/>. Acesso em: 20 jul. 2025.

IEA – INTERNATIONAL ENERGY AGENCY. Electricity 2023: analysis and forecast to 2025. Paris: IEA, 2023. Disponível em: <https://www.iea.org/reports/electricity-2023>. Acesso em: 10 jul. 2025.

IEA – INTERNATIONAL ENERGY AGENCY. Global energy review 2023: CO<sub>2</sub> emissions in 2022. Paris: IEA, 2023. Disponível em: <https://www.iea.org/reports/global-energy-review-2023/co2-emissions-in-2022>. Acesso em: 01 jul. 2025.

IPCC – INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE. Climate change 2021: the physical science basis. Cambridge: Cambridge University Press, 2021.

IPCC – Intergovernmental Panel on Climate Change. Climate Change 2021: The Physical Science Basis. Geneva: IPCC, 2021.

IRENA – INTERNATIONAL RENEWABLE ENERGY AGENCY. Renewable power generation costs in 2022. Abu Dhabi: IRENA, 2023.

JACOBSON, M. Z. et al. Low-cost solutions to global warming, air pollution, and energy insecurity for 145 countries. *Energy & Environmental Science*, v. 15, n. 3, p. 1005–1020, 2022. DOI: <https://doi.org/10.1039/D1EE00733C>. Acesso em: 10 jul. 2025.

MARTINS, R. S.; ALMEIDA, F. P. Responsabilidade socioambiental e vantagem competitiva nas empresas. *Revista de Administração Contemporânea*, v. 23, n. 1, p. 89-105, 2019.

PATTERSON, D. et al. Carbon emissions and large neural network training. arXiv preprint, arXiv:2104.10350, 2021. Disponível em: <https://arxiv.org/abs/2104.10350>. Acesso em: 01 jul. 2025.

RUSSELL, S.; NORVIG, P. Inteligência artificial. 4. ed. São Paulo: Pearson Education do Brasil, 2021.

SILVA, T. R.; PEREIRA, M. C. Energia solar e mitigação de impactos ambientais. *Revista de Engenharia Ambiental*, v. 15, n. 1, p. 77-89, 2020.



STRUBELL, E.; GANESH, A.; MCCALLUM, A. Energy and policy considerations for deep learning in NLP. In: Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics, 2019. Disponível em: <https://aclanthology.org/P19-1355.pdf>. Acesso em: 01 jul. 2025.