

# Aprendizagem Profunda e Inteligência Artificial Verde: Caminhos para um Futuro mais Sustentável Resumo Estendido – CTDG-SI 2026

Vívian Rique Gil Ferraro<sup>1</sup>, Daniel da Silva Costa (Coorientador)<sup>1</sup>,  
Pedro Nuno de Souza Moura (Orientador)<sup>1</sup>

<sup>1</sup>Universidade Federal do Estado do Rio de Janeiro (UNIRIO)  
CCET – Avenida Pasteur, 458 – Urca – 22.290-255 – Rio de Janeiro – RJ – Brasil

{viferraro, daniel.scosta}@edu.unirio.br, pedro.moura@uniriotec.br

**Abstract.** *In the last decade, there have been significant advances in the results achieved by Deep Learning models and their widespread adoption in academia and industry. Although these models have the potential to assist in the management of natural resources and environmental issues, they typically require a great deal of computing power, resulting in higher energy costs and also large carbon footprint numbers. This work seeks to highlight and discuss the energy costs involved in using neural network models, experimentally comparing some architectures in terms of performance, energy efficiency, and computational cost. The results obtained reinforce that it is possible to build models that reconcile sustainability and performance, providing subsidies for more conscious technical choices.*

## 1. Introdução

Os modelos baseados em Aprendizagem Profunda (AP), campo da Inteligência Artificial (IA), têm demonstrado melhores resultados em comparação a outras abordagens de IA e parecem ser a principal escolha de abordagem nos dias atuais.

Uma das áreas de aplicação mais importantes da AP atualmente, considerando-se os Objetivos de Desenvolvimento Sustentável<sup>1</sup>, é a modelagem de problemas do meio ambiente. Contudo, o uso desses modelos tipicamente requer um grande consumo de recursos computacionais e trabalhos recentes apontam para a necessidade de adotar medidas para minimizar esse impacto ambiental [Schwartz et al. 2020, Wolff Anthony et al. 2020, Lenherr et al. 2021].

O trabalho de [Schwartz et al. 2020] apresentou o conceito de Inteligência Artificial Verde (IA Verde), uma abordagem responsável que busca harmonizar o progresso tecnológico com a sustentabilidade ambiental e que se opõe à IA Vermelha, que prioriza o aumento do desempenho sem considerar os custos ambientais, econômicos e sociais.

Este trabalho busca então demonstrar a viabilidade de se obterem modelos de AP mais eficientes e com menor impacto ambiental. Para tal, foi conduzida uma comparação experimental de arquiteturas de redes neurais para visão computacional considerando métricas tradicionais de avaliação de desempenho associadas a métricas de eficiência energética e de custo computacional. Os resultados obtidos mostram que é possível construir modelos que consumam menos energia nas etapas de treinamento e de inferência

---

<sup>1</sup><https://www.unicef.org/brazil/objetivos-de-desenvolvimento-sustentavel>

e que tenham menor custo computacional, mas que possuam uma performance similar àquela de modelos mais dispendiosos, corroborando, assim, a proposta da IA Verde.

Este artigo corresponde a um resumo estendido do artigo publicado anteriormente no XV Workshop de Computação Aplicada à Gestão do Meio Ambiente e Recursos Naturais (WCAMA 2024) [Ferraro et al. 2024].

## 2. Materiais e Métodos

O conjunto de dados escolhido para os experimentos deste trabalho foi o MNIST, proposto por [Lecun et al. 1998], que contém dígitos manuscritos coletados de seres humanos. Já as arquiteturas de redes neurais escolhidas para a realização dos experimentos foram: LeNet-5, AlexNet, ResNet34, GoogLeNet e MobileNet. Essas foram selecionadas por serem amplamente adotadas em *benchmarks* conduzidos na área.

As métricas de avaliação de desempenho dos modelos adotadas neste trabalho foram: acurácia, precisão, revocação e a medida-F1. Já as métricas de eficiência energética utilizadas incluem a quantidade de energia elétrica utilizada pela GPU e a pegada de carbono (*carbon footprint*), convertendo-o em equivalente de dióxido de carbono ( $CO_2$ ) liberado na atmosfera. Foram também empregadas algumas métricas que refletem o custo computacional de um modelo, a saber: (i) número de parâmetros ; (ii) FLOPs (número de operações de ponto flutuante) para realizar uma determinada tarefa; (iii) tempo de treinamento; e (iv) tempo de inferência.

Na avaliação experimental, houve a adoção de duas fases: treinamento e inferência. Na primeira fase, foram treinados 10 modelos de cada uma das arquiteturas de redes neurais selecionadas, de modo que foi computada a acurácia e função de perda de cada modelo em relação aos conjuntos de treinamento e de validação, medindo-se também a eficiência energética, a pegada de carbono e o tempo de treinamento. Para cada arquitetura, foi então escolhido o modelo treinado associado à melhor acurácia alcançada no conjunto de validação, para utilização na segunda fase. Nessa fase, para cada arquitetura, o modelo escolhido foi utilizado para inferência em relação ao conjunto de testes, tomando-se as métricas de avaliação de desempenho. Por fim, foi calculado o tempo médio de inferência considerando 10 execuções consecutivas. Ademais, os seguintes valores de hiperparâmetros foram usados: tamanho de lote de 32, número máximo de épocas de 50, taxa de aprendizado de 0,001 e otimizador *Adam*.

## 3. Resultados Obtidos e Discussão

Para os valores das métricas de eficiência energética coletadas na fase de treinamento, a LeNet-5 foi a rede que gerou os menores valores de pegada de carbono e de consumo energético, correspondendo a 0,93286 gramas e 49,60409 watts, respectivamente. Logo em seguida, veio a rede MobileNet que obteve valores de pegada de carbono e de consumo energético iguais a 1,46991 gramas e 66,01626 watts, respectivamente. As demais redes apresentaram valores mais elevados para tais métricas de eficiência energética.

Já para os valores das métricas de avaliação de desempenho coletadas na fase de inferência, a rede que obteve o melhor desempenho correspondeu à AlexNet, que atingiu valores das métricas de acurácia, precisão, revocação e medida-F1 superiores a 0,99. Em seguida, vieram as redes GoogLeNet e ResNet34 que alcançaram valores também superiores a 0,99 para tais métricas de avaliação de desempenho.

A fim de se demonstrar que há, de fato, uma diferença estatisticamente significativa entre os valores de emissão de carbono e medida-F1 gerados pelas redes LeNet-5 e MobileNet (grupo 1, constituído pelas redes de menor custo computacional), e AlexNet, ResNet34 e GoogLeNet (grupo 2, constituído pelas redes de maior custo computacional), foram realizados dois testes de hipótese do tipo teste  $t$  de Welch, um para cada métrica. A hipótese nula ( $H_0$ ) foi de que não há diferença significativa entre as médias dos grupos (baixo e alto custo computacional) para a métrica em análise (emissão de carbono ou medida-F1). Desse modo, os resultados revelaram uma diferença estatisticamente significativa entre os grupos no que diz respeito à emissão de carbono ( $t = -6,21$ ,  $p = 0,01$ ) e, em relação à medida-F1, o teste não apontou uma diferença estatisticamente significativa entre os grupos ( $t = -1,67$ ,  $p = 0,34$ ).

Apesar de atingirem melhor desempenho, os resultados mostram que as redes AlexNet, ResNet34 e GoogLeNet estão associadas a valores consideravelmente maiores de emissão de carbono e consumo de energia do que as redes LeNet-5 e MobileNet. Ao mesmo tempo em que são mais econômicas do ponto vista energético e exigem menos recursos computacionais, as redes LeNet-5 e MobileNet conseguem atingir um valor apenas ligeiramente inferior para as métricas de desempenho quando aplicadas à base MNIST. Assim, nesse caso, essas redes podem ser uma opção mais viável e sustentável do que as redes mais complexas, indo ao encontro do que é preconizado pela IA Verde.

#### 4. Conclusão

A partir das análises realizadas, demonstrou-se que o paradigma da IA Verde não apenas é necessário, como é tecnicamente viável, uma vez que arquiteturas otimizadas e modelos menos complexos são capazes de entregar resultados satisfatórios com uma fração do consumo energético. Em última análise, este trabalho reforça que a sustentabilidade de sistemas de informação inteligentes deve ser centrada na sua capacidade de operar de forma harmoniosa com os recursos globais, consolidando a eficiência energética como um critério indispensável para a inovação responsável em IA.

#### Referências

- Ferraro, V., Gullo, G., Costa, D., and Moura, P. (2024). Aprendizagem profunda e inteligência artificial verde: Caminhos para um futuro mais sustentável. In *Anais do XV Workshop de Computação Aplicada à Gestão do Meio Ambiente e Recursos Naturais*, pages 159–168, Porto Alegre, RS, Brasil. SBC.
- Lecun, Y., Bottou, L., Bengio, Y., and Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11):2278–2324.
- Lenherr, N., Pawlitzek, R., and Michel, B. (2021). New universal sustainability metrics to assess edge intelligence. *Sustainable Computing: Informatics and Systems*, 31:100580.
- Schwartz, R., Dodge, J., Smith, N. A., and Etzioni, O. (2020). Green ai. *Communications of the ACM*, 63(12):54–63.
- Wolff Anthony, L. F., Kanding, B., and Selvan, R. (2020). Carbontracker: Tracking and predicting the carbon footprint of training deep learning models. *arXiv.org*.