

Green AI aplicada à detecção de incêndios florestais: comparação entre desempenho preditivo e eficiência energética de redes neurais convolucionais

Laís S. Rocha, Livia A. Lopes e Aline F. G. Sousa

Resumo— A detecção de incêndios florestais por sensoriamento remoto é essencial para reduzir impactos ambientais. Este trabalho compara as arquiteturas ResNet50, VGG19 e MobileNetV3 na detecção de incêndios em imagens Landsat-8 e Landsat-9, incorporando métricas de *Green AI*. A ResNet50 apresentou o maior desempenho preditivo, com acurácia de 85%, AUC de 0.95 e ausência de falsos negativos. A VGG19 apresentou maior consumo energético e menor sensibilidade à classe incêndio. A MobileNetV3 destacou-se pela menor emissão de carbono, menor consumo energético e menor tempo de inferência, mostrando-se adequada para aplicações em larga escala.

Palavras-Chave— incêndios florestais, redes neurais convolucionais, imagens de satélite, *Green AI*, eficiência energética.

Abstract— Wildfire detection through remote sensing is essential for reducing environmental impacts. This work compares the ResNet50, VGG19, and MobileNetV3 architectures for wildfire detection using Landsat-8 and Landsat-9 imagery, incorporating Green AI metrics. ResNet50 achieved the best predictive performance, reaching 85% accuracy, an AUC of 0.95, and zero false negatives. VGG19 presented higher energy consumption and lower sensitivity to the wildfire class. MobileNetV3 stood out for its lower carbon emissions, reduced energy consumption, and shorter inference time, demonstrating its suitability for large-scale and resource-constrained applications.

Keywords— forest fires, convolutional neural networks, satellite imagery, *Green AI*, energy efficiency.

I. INTRODUÇÃO

A recorrência de incêndios florestais tem se tornado uma preocupação global crescente, especialmente na última década, devido aos impactos sociais, ambientais e econômicos associados. Esses eventos podem ultrapassar as áreas diretamente afetadas, uma vez que o fogo se propaga rapidamente para regiões vizinhas [1]. Nesse cenário, a Floresta Amazônica destaca-se pela intensificação das queimadas e pelos impactos associados à sua preservação.

Dados do MAPBIOMAS [2] indicam a gravidade do cenário: em 2024, o Pará registrou a maior área queimada do Brasil, com 7,1 milhões de hectares, correspondendo a 24% do total nacional e a um aumento de 173% em relação à média anual. Embora tenha apresentado redução em 2025, o estado ainda demanda estratégias de prevenção e controle [3]. Além disso, a ocorrência de incêndios florestais se estende a outras regiões amazônicas, como o Amazonas, região de origem do

conjunto de dados utilizado neste trabalho [5], reforçando a necessidade de soluções de detecção aplicáveis à Amazônia.

Nesse contexto, a integração entre *deep learning* e sensoriamento remoto apresenta-se como uma abordagem promissora para a detecção automática de incêndios florestais. A capacidade das redes neurais profundas de extrair padrões complexos de grandes volumes de dados, aliada ao monitoramento contínuo por satélite, possibilita identificar focos de calor antes de sua expansão e auxiliar na tomada de decisões estratégicas [4].

Entretanto, embora apresentem elevado desempenho preditivo, arquiteturas profundas de Redes Neurais Convolucionais (RNCs) demandam alto custo computacional nas etapas de treinamento e inferência, resultando em maior consumo energético e emissões de carbono. Esse cenário reforça a necessidade de soluções que conciliem capacidade de detecção, eficiência computacional e sustentabilidade.

Nesse contexto, a Inteligência Artificial Verde (*Green AI*) propõe modelos que equilibrem desempenho e custo computacional [8]. Enquanto arquiteturas tradicionais, como VGG19, priorizam capacidade representacional, modelos como MobileNetV3 são desenvolvidos para reduzir a demanda por recursos, sendo mais adequados a ambientes com restrições de hardware.

Assim, este trabalho compara as arquiteturas ResNet50, VGG19 e MobileNetV3 na detecção de incêndios florestais em imagens Landsat-8 e Landsat-9, avaliando não apenas o desempenho preditivo, mas também aspectos de eficiência energética e impacto ambiental, incluindo consumo de energia, emissão de carbono computacional e custo computacional.

II. TRABALHOS RELACIONADOS

No contexto da detecção de incêndios na Amazônia, o estudo de Eleutério et al. [5] destaca-se ao utilizar imagens dos satélites Landsat-8 e Landsat-9 para treinar uma Rede Neural Artificial (RNA) de classificação binária. O desafio intencional abordado por esses autores foi a ausência de tratamento específico para a interferência de nuvens durante o pré-processamento. Essa escolha visou avaliar a robustez do modelo em condições realistas, onde a presença de nuvens é inevitável na região tropical, resultando em uma acurácia de 97,5% e provando a eficácia da rede mesmo sob obstruções atmosféricas. Complementando essa frente, Fusioka [6] explorou a segmentação de fogo ativo através de variações da arquitetura U-Net (incluindo as versões 10c, 3c e U-Net-Light). Fusioka evidenciou que modelos mais compactos

conseguem replicar resultados de algoritmos tradicionais com menor custo computacional, obtendo *F1-Score* entre 84,2% e 94,2%.

A eficácia de arquiteturas consagradas também foi validada por Blasi [7], que aplicou *fine-tuning* na VGG19 para incêndios em imagens RGB (*red, green, blue*), atingindo acurácia superior a 98%, mas levantando questões sobre sustentabilidade computacional. O conceito de *Green AI*, que prioriza eficiência computacional sobre ganho marginal de desempenho, foi proposto por Schwartz et al. [8]. Ferraro [9] comparou LeNet-5, AlexNet, ResNet34, GoogLeNet e MobileNet, constatando que a AlexNet possui pegada de carbono até sete vezes superior à LeNet-5. Gonçalves et al. [10], aplicando quantização de precisão mista em VGG11 e ResNet34, mostraram que reduzir a ResNet34 para 16 bits diminui em 32,96% as emissões sem comprometer as previsões.

Este trabalho se posiciona na intersecção entre a detecção de incêndios florestais na Amazônia e a responsabilidade energética. Enquanto Eleutério et al. [5] e Fusioka [6] focam na precisão do monitoramento, e Ferraro [9] e Gonçalves et al. [10] analisam a *Green AI* em bases de *benchmark* (MNIST e CIFAR-10), este artigo aplica métricas de sustentabilidade (via *CodeCarbon*) diretamente ao monitoramento térmico florestal, comparando as arquiteturas ResNet50, VGG19 e MobileNetV3 em busca do equilíbrio entre robustez e eficiência energética para a Floresta Amazônica.

III. METODOLOGIA

A. Ambiente computacional

O ambiente computacional utilizado nos experimentos consiste em um processador AMD Ryzen 5 2500U, com frequência de 2GHz, 16GB de memória RAM DDR4 e processamento gráfico AMD Radeon™ Vega 8 Graphics. Os experimentos foram realizados em um sistema equipado com processador AMD Ryzen 5 2500U (2GHz), 16GB de memória RAM DDR4 e GPU integrada AMD Radeon™ Vega 8 Graphics.

B. Dataset

Os experimentos utilizaram o *dataset* disponibilizado por Eleutério et al. [5], composto por 524 imagens de resolução 150×150 pixels, obtidas a partir de recortes de 26 imagens dos satélites Landsat-8 e Landsat-9, disponibilizadas pela plataforma *EarthExplorer*. As imagens foram coletadas no estado do Amazonas entre setembro e outubro de 2023 e 2024, período correspondente à estiagem na região amazônica, quando a incidência de incêndios florestais é mais elevada.

Do total de imagens, 400 foram utilizadas para treinamento, 84 para validação e 40 para teste. O conjunto de teste (40 imagens) foi mantido isolado e utilizado exclusivamente na avaliação final do melhor modelo de cada arquitetura. Os conjuntos de treinamento e validação contêm 242 imagens da classe *fire*, representando cenas com incêndios florestais, e 242 da classe *no_fire*, correspondentes a ambientes sem ocorrência de incêndios.

As imagens utilizam uma composição *falsa-cor* formada pelas bandas 7 (SWIR2), 5 (infravermelho próximo) e 2 (azul) dos satélites Landsat-8 e Landsat-9, escolhida por Eleutério

et al. [5] por realçar emissões térmicas e estresse da vegetação associados a incêndios. As cenas correspondem a produtos *Landsat Collection 2 Level-2 (Surface Reflectance)*, previamente corrigidos atmosféricamente e georreferenciados pelo *United States Geological Survey (USGS)*. Seguindo a metodologia da base original, não foi realizado mascaramento ou remoção de nuvens, preservando as condições reais de aquisição.

Os rótulos seguiram o critério de Eleutério et al. [5]: uma imagem foi classificada como *fire* quando apresentava evidência visual de foco ativo de incêndio, identificada pela composição SWIR2-NIR-Azul, independentemente da área ocupada pelas chamas. A base original não especifica o tratamento de casos ambíguos, como cenas contendo apenas fumaça sem foco visível, limitação também presente neste trabalho.

C. Métricas de desempenho preditivo

O desempenho das arquiteturas foi avaliado por meio das métricas acurácia (*accuracy*), precisão (*precision*), revocação (*recall*), *F1-Score* e a *Area Under the Curve (AUC)*, calculada a partir da curva ROC (*Receiver Operating Characteristic*).

A acurácia (Equação 1) mede a proporção de classificações corretas realizadas pelo modelo. A *Precision* (Equação 2) indica a proporção de positivos corretamente classificados. O *Recall* (Equação 3) mede a capacidade de identificar os verdadeiros positivos. O *F1-Score* (Equação 4) é à média harmônica entre *Precision* e *Recall*.

$$Accuracy = \frac{VP + VN}{VP + VN + FP + FN}. \quad (1)$$

$$Precision = \frac{VP}{VP + FP}. \quad (2)$$

$$Recall = \frac{VP}{VP + FN}. \quad (3)$$

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall}. \quad (4)$$

As métricas *Precision*, *Recall* e *F1-Score* foram obtidas pela média macro das classes *fire* e *no_fire*, calculada a partir da média aritmética dos valores individuais de cada classe. Essa abordagem atribui a mesma importância às duas classes, reduzindo o impacto de possíveis diferenças na distribuição dos exemplos do conjunto de teste.

A métrica AUC (Equação 5), foi utilizada para avaliar a capacidade de separação entre as classes *fire* e *no_fire*, sendo melhores os valores mais próximos de 1.

$$AUC = \int_0^1 TPR(FPR^{-1}(x)) dx, \quad (5)$$

em que TPR (*True Positive Rate*) representa a taxa de verdadeiros positivos e FPR (*False Positive Rate*) representa a taxa de falsos positivos.

Nas equações apresentadas, *VP*, *VN*, *FP* e *FN* representam, respectivamente, verdadeiros positivos, verdadeiros negativos, falsos positivos e falsos negativos.

D. Métricas de eficiência energética

Na avaliação dos modelos foi considerado, além das métricas tradicionais de desempenho, indicadores relacionados à eficiência energética e custo computacional. As métricas avaliadas compreendem: emissão de carbono (CO_2), consumo de energia (Wh), complexidade do modelo (número de parâmetros e FLOPs) e tempo de processamento (treino e validação).

1) *Consumo energético e emissão de carbono*: O consumo de CPU (AMD Ryzen 5 2500U) e de memória RAM foi estimado a partir de valores de referência de TDP (*Thermal Design Power*, potência de projeto térmico), uma vez que a leitura direta via RAPL (*Running Average Power Limit*) não está disponível para a plataforma de hardware utilizada. O consumo da GPU integrada (AMD Radeon™ Vega 8) não foi mensurado, dado que o CodeCarbon oferece suporte a monitoramento direto apenas para GPUs NVIDIA via NVML (*NVIDIA Management Library*). A intensidade de carbono considerada corresponde à matriz elétrica do estado do Pará, determinada automaticamente pela ferramenta via geolocalização. As emissões e o consumo energético foram medidos de forma cumulativa ao longo dos 5 *folds* da validação cruzada, sendo os valores da Tabela IV obtidos pela divisão dos totais acumulados pelo número de *folds*.

A emissão equivalente de dióxido de carbono (CO_2) é estimada a partir da energia consumida e da intensidade de carbono da matriz elétrica utilizada, conforme Equação (6):

$$CO_2 = E \times CI, \quad (6)$$

onde E representa a energia consumida em Wh e CI corresponde à intensidade de carbono da rede elétrica, expressa em gCO_2/Wh .

A energia consumida é estimada pela relação (Equação 7):

$$E = P \times t, \quad (7)$$

em que P representa a potência média consumida pelo sistema computacional e t corresponde ao tempo total de execução do treinamento.

2) *Complexidade do modelo*: A complexidade das redes neurais foi avaliada sob duas perspectivas: número total de parâmetros e operações de ponto flutuante (FLOPs). O número total de parâmetros refere-se à quantidade de pesos ajustáveis que a rede precisa armazenar. Já os FLOPs quantificam o custo computacional teórico de uma única passagem pela rede.

3) *Tempo de treinamento e validação*: O tempo de treinamento corresponde à média do tempo de execução das etapas de *Head Training* (base convolucional congelada) e *Fine-Tuning* (descongelamento das últimas camadas convolucionais) ao longo dos k *folds* da validação cruzada. O tempo de validação representa a latência média de inferência por imagem, calculada a partir do tempo total de processamento do conjunto de teste (40 imagens). Embora essa abordagem seja adequada para comparação relativa entre arquiteturas, a medição foi realizada em uma única execução, podendo apresentar variações associadas ao sistema operacional. Avaliações futuras podem utilizar múltiplas repetições para obter estimativas mais robustas da latência.

E. Ajuste de hiperparâmetros

Com o objetivo de reduzir vieses associados à divisão dos dados, empregou-se validação cruzada estratificada (*Stratified K-Fold*) com $k = 5$ sobre o conjunto combinado de treino e validação (484 imagens).

Para reduzir a variabilidade na divisão dos dados, foi fixada a semente aleatória ($seed=42$) na validação cruzada estratificada. Entretanto, a inicialização dos pesos e as operações de *data augmentation* (*RandomFlip* e *RandomRotation*) não utilizaram sementes fixas, podendo introduzir variabilidade residual entre execuções.

Durante o treinamento, foram aplicadas técnicas de *data augmentation*, incluindo rotações e espelhamentos. O processo de otimização utilizou o algoritmo Adam, função de perda *Binary Cross-Entropy* e *batch size* igual a 32.

O treinamento foi dividido em duas etapas: *Head Training*, com a base convolucional congelada durante 8 épocas, e *Fine-Tuning*, com descongelamento das últimas camadas convolucionais por 12 épocas adicionais. As taxas de aprendizagem adotadas foram de 10^{-3} e 10^{-6} , respectivamente.

Em ambas as fases, utilizou-se *Early Stopping* com *patience=5* e restauração automática dos melhores pesos, com o objetivo de minimizar problemas de sobreajuste (*overfitting*). Também foi empregado o mecanismo *ReduceLROnPlateau*, configurado com *patience=3* e *factor=0.2* para ajuste dinâmico da taxa de aprendizagem.

IV. RESULTADOS E DISCUSSÕES

A. Dinâmica de treinamento e convergência

A Figura 1 apresenta as curvas da função de perda (*loss*) para os melhores modelos das arquiteturas ResNet50, MobileNetV3 e VGG19, respectivamente. A linha vertical verde pontilhada indica o início da etapa de *Fine-Tuning*.

É possível perceber um padrão consistente de convergência nas três arquiteturas: nas primeiras 8 épocas (*Transfer Learning*), a perda decai acentuadamente, indicando rápida adaptação dos pesos pré-treinados; após a época 8 (*Fine-Tuning*), as curvas estabilizam. A perda de validação manteve-se consistentemente abaixo ou próxima da perda de treino, sugerindo ausência de *overfitting* evidente — embora esse comportamento também possa decorrer de *data augmentation*, regularização ou diferenças entre os subconjuntos, não garantindo boa generalização fora do domínio avaliado.

B. Desempenho preditivo das arquiteturas

1) *Avaliação na validação*: A avaliação de desempenho durante a fase de validação foi realizada com base nas métricas de perda (*loss*), acurácia (*accuracy*) e AUC, considerando o valor médio (μ) e o desvio padrão (σ) resultantes da validação cruzada. A Tabela I apresenta os resultados obtidos pelas arquiteturas avaliadas.

Observa-se estabilidade no treinamento das três arquiteturas, evidenciada pelos baixos desvios padrão. A ResNet50 obteve o maior AUC (0,9331) e acurácia de 0,8408, indicando elevada capacidade de distinção entre as classes. A MobileNetV3 apresentou a maior acurácia global (0,8508), com AUC (0,9262)




Fig. 1. Curvas de perda dos melhores modelos obtidos para cada arquitetura: (a) ResNet50, (b) MobileNetV3 e (c) VGG19.

TABELA I

DESEMPENHO MÉDIO NA FASE DE VALIDAÇÃO ($\mu \pm \sigma$).

Métrica	ResNet50	MobileNetV3	VGG19
Loss	0.5119 $\pm$ 0.0338	0.5961 $\pm$ 0.0501	0.6366 $\pm$ 0.0759
Accuracy	0.8408 $\pm$ 0.0281	0.8508 $\pm$ 0.0425	0.8243 $\pm$ 0.0393
AUC	0.9331 $\pm$ 0.0175	0.9262 $\pm$ 0.0257	0.9151 $\pm$ 0.0368

ligeiramente inferior ao da ResNet50. A VGG19 registrou os valores mais baixos (acurácia de 0,8243 e AUC de 0,9151), além de desvios padrão superiores às demais, especialmente na perda.

2) *Avaliação no conjunto de teste*: A avaliação dos modelos na etapa de teste foi realizada utilizando 40 imagens não vistas anteriormente durante o treinamento e validação. Destas 40 imagens, 24 apresentam focos de incêndio florestal e 16 não apresentam. A Tabela II apresenta as métricas obtidas: acurácia, perda (*loss*), *precision*, *recall*, *F1-Score* e AUC para cada uma das arquiteturas avaliadas.

TABELA II

MÉTRICAS DE DESEMPENHO NO CONJUNTO DE TESTE.

Métrica	ResNet50	MobileNetV3	VGG19
Acurácia	0.8500	0.8250	0.8250
Loss	0.3259	0.2973	0.5126
Precision	0.9000	0.8200	0.8300
Recall	0.8100	0.8100	0.8400
F1-Score	0.8300	0.8200	0.8200
AUC	0.9500	0.9400	0.9000

A arquitetura ResNet50 apresentou superioridade nas métricas de desempenho, alcançando a maior acurácia (0.8500), a maior *precision* (0.9000), o maior *F1-score* (0.8300) e o maior valor de AUC (0.9500). Destaca-se também o desempenho da MobileNetV3 que, apesar de ser uma arquitetura mais leve, obteve o menor valor de perda (0.2973). A arquitetura VGG19 obteve o maior valor de *recall* (0.8400).

Para uma análise detalhada dos erros e acertos, as matrizes de confusão de cada uma das arquiteturas avaliadas apresentaram os valores de VP, FP, VN e FN, que podem ser observados na Tabela III.

A ResNet50 demonstrou o comportamento mais seguro para a detecção de focos de incêndio, classificando corretamente (VP) todas as 24 instâncias da classe *fire*, com zero FN. O *Recall* macro de 0,8100 reportado na Tabela II resulta da média entre o *Recall* de 1,000 para *fire* e 0,625 para *no_fire*, este último puxado para baixo pelos 6 falsos positivos — mas

TABELA III

ELEMENTOS DA MATRIZ DE CONFUSÃO (VP, FN, VN E FP) E RECALL POR CLASSE OBTIDOS PELAS ARQUITETURAS AVALIADAS.

Arquitetura	VP	FN	VN	FP	Recall (<i>fire</i>)	Recall (<i>no_fire</i>)
ResNet50	24	0	10	6	1,000	0,625
VGG19	18	6	15	1	0,750	0,938
MobileNetV3	21	3	12	4	0,875	0,750

o *Recall* específico para *fire* de 1,000 torna esta arquitetura a mais sensível para a aplicação em termos de detecção de incêndios.

A VGG19 identificou corretamente 15 das 16 imagens sem fogo (*Recall* de 0,938 para *no_fire*), mas deixou de detectar 6 dos 24 focos reais de incêndio (*Recall* de 0,750 para *fire*), o que representa um risco considerável em aplicações reais. Já a MobileNetV3 apresentou desempenho intermediário e equilibrado entre as classes, com 3 falsos negativos e 4 falsos positivos.

C. Eficiência energética e custo computacional

Seguindo os princípios da *Green AI*, esta etapa avaliou o custo ambiental associado ao treinamento de cada arquitetura. A Tabela IV apresenta os resultados de emissão de carbono expressas em gramas de carbono (g CO₂), consumo de energia convertidos para Watt-hora (Wh) e a comparação do custo computacional entre as arquiteturas. Esses valores foram medidos de forma cumulativa ao longo dos cinco *folds* da validação cruzada de cada arquitetura, sendo os valores apresentados na Tabela IV obtidos pela divisão dos totais acumulados pelo número de *folds*.

TABELA IV

EMIÇÃO DE CARBONO (g CO₂), CONSUMO DE ENERGIA (Wh) E EFICIÊNCIA COMPUTACIONAL MEDIDOS DURANTE O TREINAMENTO.

Métrica	ResNet50	MobileNetV3	VGG19
g CO ₂	2.15	0.49	7.60
Wh	21.90	4.97	77.29
Nº de parâmetros (M)	25.60	3.90	143.60
FLOPs (bn)	4.10	0.22	19.60
Tempo de treino (s)	1126.27	255.00	3975.54
Tempo de validação (ms)	231.66	116.90	331.48

A análise das métricas de eficiência computacional revelou diferenças expressivas entre os modelos. A arquitetura VGG19

apresentou o maior consumo de energia (77.29 Wh) e emissão de carbono (7.60g). Esse elevado custo está associado ao número de parâmetros (143.60 milhões, frente a 25.60 milhões da ResNet50 e 3.90 milhões da MobileNetV3), decorrente de sua arquitetura baseada em blocos convolucionais densos seguidos de camadas totalmente conectadas de grande dimensão, sem os atalhos residuais (*skip connections*) presentes na ResNet50 nem as convoluções *depthwise-separable* empregadas na MobileNetV3, que reduzem substancialmente o número de operações por camada. Em comparação com a MobileNetV3, que obteve valor de emissão de carbono igual a 0.49g, a VGG19 emitiu aproximadamente 15 (quinze) vezes mais carbono para atingir o mesmo *F1-Score* (0.8200) e acurácia (0.8250).

No conjunto de dados avaliado, a ResNet50 apresentou o maior desempenho preditivo entre as arquiteturas analisadas, embora tenha exibido custo intermediário, com emissões de 2,15 g de carbono, valor superior em mais de quatro vezes ao observado na MobileNetV3.

Em relação ao tempo de validação, fator crítico para aplicações em tempo real, a MobileNetV3 destacou-se com a menor latência (116.90 ms), sendo aproximadamente 3 (três) vezes mais rápida que a VGG19 (331.48 ms) e cerca de duas vezes mais rápida que a ResNet50 (231.66 ms).

V. CONCLUSÕES

Este trabalho teve como objetivo realizar uma análise comparativa entre diferentes arquiteturas de RNCs, especificamente ResNet50, VGG19 e MobileNetV3, aplicadas à detecção de incêndios florestais a partir de imagens dos satélites Landsat-8 e Landsat-9. Cabe destacar que o escopo deste estudo se limita à classificação binária de recortes estáticos de imagens de satélite, não abrangendo a avaliação de um sistema de monitoramento em fluxo contínuo, com aspectos como latência de revisita orbital, cobertura de nuvens e fumaça em tempo real, e custo de processamento em mosaicos de maior escala — questões que permanecem como direções relevantes para trabalhos futuros.

Como diferencial, a pesquisa incorporou a perspectiva da *Green AI*, avaliando não apenas o desempenho preditivo dos modelos, mas também o consumo energético e as emissões de carbono associados ao treinamento. Os valores reportados referem-se exclusivamente a essa etapa, embora, em aplicações de larga escala, como o monitoramento contínuo de áreas florestais, o custo energético da inferência também possa representar uma parcela relevante do impacto ambiental operacional.

Entre as arquiteturas avaliadas, a ResNet50 consolidou-se como a solução mais robusta para a aplicação, alcançando o maior valor de AUC (0.950) e apresentando zero FN para a classe *fire* durante a etapa de teste, o que evidenciou sua adequação para sistemas de monitoramento crítico.

Sob a perspectiva da eficiência energética, a MobileNetV3 apresentou os resultados mais expressivos. Essa arquitetura demonstrou ser capaz de manter razoável desempenho preditivo, alcançando acurácia de 82.5% e perda de 0.2973, com custo computacional significativamente reduzido. Além disso, a MobileNetV3 apresentou emissão de carbono aproximadamente

15 vezes inferior à observada na VGG19 e tempo de validação cerca de duas vezes menor em comparação à ResNet50.

Por outro lado, a arquitetura VGG19 mostrou-se menos vantajosa para a aplicação investigada. Apesar de apresentar métricas médias competitivas, seu elevado consumo energético, maior emissão de carbono e falhas na detecção de focos reais de incêndio, evidenciadas pelos FN, indicam que arquiteturas excessivamente profundas e densas nem sempre resultam em melhor desempenho prático.

Dessa forma, os resultados deste estudo indicam que a escolha da arquitetura mais adequada envolve um *trade-off* entre desempenho preditivo e responsabilidade ecológica. Em cenários nos quais a sensibilidade na detecção constitui requisito prioritário, a ResNet50 mostrou-se a alternativa mais adequada. Por outro lado, para aplicações em larga escala alinhadas aos princípios da *Green AI*, a MobileNetV3 apresentou-se como uma alternativa altamente competitiva.

Como perspectiva para trabalhos futuros, propõe-se a investigação de técnicas avançadas de eficiência, como quantização e poda de redes (*pruning*), com foco na redução da pegada de carbono. O objetivo central consiste em mitigar o paradoxo tecnológico discutido nesta pesquisa, buscando garantir que ferramentas de Inteligência Artificial desenvolvidas para proteção ambiental não contribuam, por meio de suas próprias emissões de carbono, para o aquecimento global associado à intensificação dos incêndios que se propõem a combater.

AGRADECIMENTOS

Ao grupo de pesquisa em Visão Computacional e Aprendizado de Máquina (VICAM) pelo suporte técnico.

REFERÊNCIAS

- [1] C. Petesch, "Africa is the 'fire continent' but blazes differ from Amazon," 2019. [Online]. Disponível em: <https://bit.ly/3aSljQn>.
- [2] MAPBIOMAS, *Relatório Anual do Fogo (RAF)* - Ed. 2024. 2024. [Online]. Disponível em: https://brasil.mapbiomas.org/wp-content/uploads/sites/4/2025/06/RAF2024_24_06.2025_v2.pdf.
- [3] INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE), "TerraBrasilis: Portal de Monitoramento de Queimadas," 2026. [Online]. Disponível em: <https://terrabrasilis.dpi.inpe.br/queimadas/portal/>.
- [4] M. Park, D. Q. Tran, J. Bak, and S. Park, "Advanced wildfire detection using generative adversarial network-based augmented datasets and weakly supervised object localization," *International Journal of Applied Earth Observation and Geoinformation*, vol. 114, 2022.
- [5] C. L. Eleutério et al., "Identifying wildfires with convolutional neural networks and remote sensing: application to Amazon Rainforest," *International Journal of Remote Sensing*, vol. 46, no. 7, 2024.
- [6] A. M. Fusioka, *Detecção de fogo ativo por aprendizado profundo em imagens provenientes do satélite Landsat-8*. M.S. dissertation, Universidade Tecnológica Federal do Paraná, Curitiba, Brazil, 2021.
- [7] T. S. Blasi, *Classificação de incêndios florestais por meio de técnicas de visão computacional e uso de redes neurais convolucionais*. Undergraduate thesis, Instituto Federal de São Paulo, São João da Boa Vista, Brazil, 2023.
- [8] R. Schwartz, J. Dodge, N. A. Smith, and O. Etzioni, "Green AI," *Communications of the ACM*, vol. 63, no. 12, 2020.
- [9] G. R. V. Ferraro, *Aprendizagem Profunda e Inteligência Artificial Verde: Caminhos para um Futuro mais Sustentável*. Undergraduate thesis, Universidade Federal do Estado do Rio de Janeiro, 2025.
- [10] E. F. Gonçalves, P. N. de S. Moura, D. da S. Costa, and A. C. F. Alvim, "Inteligência Artificial Verde e Quantização em Modelos de Aprendizagem Profunda," in *Anais do XVI Workshop de Computação Aplicada à Gestão do Meio Ambiente e Recursos Naturais (WCAMA)*, Maceió, Brazil, 2025, Porto Alegre: Sociedade Brasileira de Computação, 2025.