

ARTIGO DE PESQUISA/RESEARCH PAPER

Detecção de Garimpo na Amazônia com Visão Computacional e Redes Neurais Convolucionais

Detecting Mining in the Amazon Using Computer Vision and Convolutional Neural Networks

Leonardo Fajardo Grupioni ✉ [Pontifícia Universidade Católica de São Paulo | leofgrupioni@gmail.com]

Felipe Valencia de Almeida [Universidade de São Paulo | fvalencia@usp.br]

Thomas Jean Georges Gallois [Instituto de Pesquisa e Formação Indígena - Iepé | thomaz@institutoiepe.org.br]

Edith Ranzini [Pontifícia Universidade Católica de São Paulo | edith@pucsp.br]

✉ Departamento de Ciência da Computação, Faculdade de Ciências Exatas e Tecnologia, Pontifícia Universidade Católica de São Paulo, R. Marquês de Paranaguá, 111 - Consolação, São Paulo - SP, 01303-050, Brasil.

Resumo. O avanço do garimpo na Amazônia brasileira configura uma das principais ameaças à biodiversidade e às comunidades locais, exigindo mecanismos de monitoramento ágeis e escaláveis. Este trabalho propõe o desenvolvimento de um modelo de visão computacional baseado em Redes Neurais Convolucionais (CNNs) para a detecção de frentes de mineração em imagens de satélite. A metodologia utilizou a plataforma Google Earth Engine para a coleta e pré-processamento de dados, resultando na construção de um dataset balanceado com mais de 111 mil recortes de imagem, devidamente rotulados e curados para mitigar a interferência de nuvens. Para validar a abordagem, estabeleceu-se primeiramente um baseline com o algoritmo Random Forest, que atingiu uma acurácia de 72% e Área Sob a Curva (AUC) de 0,80, evidenciando as limitações de métodos baseados apenas em estatísticas de pixel. Em contrapartida, a implementação da arquitetura EfficientNet-B0, aliada a técnicas de Transferência de Aprendizado e Fine-Tuning, superou significativamente os modelos tradicionais, alcançando uma acurácia de 85,92% e uma AUC de 0,9371. Os resultados demonstram que o Aprendizado Profundo é capaz de extrair características espaciais complexas, distinguindo efetivamente cicatrizes de garimpo de outros alvos visuais ambíguos. Como contribuição à comunidade científica e ao suporte à fiscalização, todo o código-fonte desenvolvido e a metodologia de criação do conjunto de dados foram disponibilizados em repositório aberto, fomentando a reprodutibilidade e a continuidade das pesquisas no monitoramento do bioma amazônico.

Abstract. The expansion of illegal mining in the Brazilian Amazon poses a major threat to biodiversity and local communities, demanding agile and scalable monitoring mechanisms. This work proposes the development of a computer vision model based on Convolutional Neural Networks (CNNs) for the detection of mining fronts using satellite imagery. The methodology employed the Google Earth Engine platform for data collection and pre-processing, resulting in a balanced dataset containing over 111,000 image chips, labeled and curated to mitigate cloud interference. To validate the approach, a baseline was established using the Random Forest algorithm, which reached an accuracy ceiling of 72% and an Area Under the Curve (AUC) of 0.80, highlighting the limitations of pixel-based statistical methods. In contrast, the implementation of the EfficientNet-B0 architecture, combined with Transfer Learning and Fine-Tuning techniques, significantly outperformed traditional models, achieving an accuracy of 85.92% and an AUC of 0.9371. The results demonstrate that Deep Learning can effectively extract complex spatial features, distinguishing mining scars from other ambiguous visual targets. As a contribution to the scientific community and environmental enforcement efforts, the entire source code and the dataset creation methodology have been made available in an open repository, promoting reproducibility and further research on Amazon biome monitoring.

Palavras-chave: Visão Computacional; Garimpo; Amazônia; Aprendizado Profundo; Sensoriamento Remoto; EfficientNet.

Keywords: Computer Vision; Mining; Amazon; Deep Learning; Remote Sensing; EfficientNet.

Recebido/Received: 06 February 2026 • **Aceito/Accepted:** 03 May 2026 • **Publicado/Published:** 15 May 2026

1 Introdução

O avanço do garimpo na Amazônia brasileira configura-se como uma das principais ameaças socioambientais e econômicas da região. Essa prática predatória provoca perdas florestais, degrada a qualidade da água, contamina solos com mercúrio e afeta diretamente a saúde e o modo de vida das populações indígenas e ribeirinhas [Global Initiative Against Transnational Organized Crime, 2023]. Segundo dados do MapBiomas, mais de 92% da área minerada no Brasil em 2022 concentrou-se na Amazônia, com aumento de aproximadamente 35 mil hectares em um único ano [MapBiomas,

2023]. A Rede Amazônica de Informação Socioambiental Georreferenciada (RAISG) mapeou 4.472 frentes de mineração ilegal em atividade, muitas delas sobrepostas a Terras Indígenas e Unidades de Conservação [RAISG, 2025].

No Brasil, sistemas de alerta como o DETER, do Instituto Nacional de Pesquisas Espaciais, permitem a detecção quase em tempo real do desmatamento [Instituto Nacional de Pesquisas Espaciais, 2024]. Entretanto, a identificação específica de frentes de garimpo ainda depende, em grande medida, de inspeções presenciais ou análises visuais pontuais de imagens de alta resolução por especialistas, o que limita a

escala, a frequência e a reprodutibilidade do monitoramento [Molina, 2023].

Nesse contexto, técnicas de Visão Computacional associadas ao Aprendizado Profundo surgem como uma alternativa promissora para automatizar e acelerar a detecção de padrões visuais característicos do garimpo, como clareiras irregulares, solo exposto e sedimentos em suspensão nos cursos d'água. Modelos baseados em Redes Neurais Convolucionais (CNNs), quando treinados com grandes volumes de imagens multiespectrais, são capazes de explorar o contexto espacial e espectral dos dados, reduzindo ambiguidades visuais e fornecendo mapas de probabilidade que podem subsidiar ações de fiscalização mais eficientes [Rodrigues, 2024; Camalan *et al.*, 2022].

Frente a esse cenário, este artigo descreve o desenvolvimento e a avaliação de modelos de Visão Computacional baseados em Aprendizado de Máquina e Aprendizado Profundo com Redes Neurais Convolucionais para a detecção de garimpo na Amazônia, utilizando imagens de satélite multiespectrais e dados georreferenciados. Como contribuições principais, destacam-se: (i) a construção de um dataset balanceado de áreas com e sem garimpo a partir do Google Earth Engine, integrando dados Sentinel-2, MapBiomas e RAISG; (ii) a comparação entre modelos clássicos de aprendizado de máquina e arquiteturas convolucionais profundas; (iii) a avaliação quantitativa do desempenho por meio de métricas como acurácia, precisão, revocação, F1-score e AUC; e (iv) a disponibilização do código-fonte e dos artefatos experimentais em repositório público, fomentando a reprodutibilidade e o uso prático da abordagem proposta.

2 Trabalhos Relacionados

A detecção de garimpo e de outros impactos ambientais na Amazônia tem sido investigada a partir de diferentes abordagens, combinando sensoriamento remoto, aprendizado de máquina e, mais recentemente, aprendizado profundo. Estudos anteriores variam desde métodos baseados em atributos espectrais e modelos supervisionados clássicos até arquiteturas convolucionais profundas aplicadas a dados multiespectrais e multitemporais. A Tabela 1 sintetiza os principais trabalhos relacionados, destacando suas estratégias metodológicas, tipos de dados utilizados e resultados alcançados, permitindo posicionar esta pesquisa no contexto da evolução dessas abordagens.

O trabalho intitulado “Aprimoramento da Detecção de Áreas de Garimpo na Região do Tapajós através de Redes Adversárias de Super-Resolução”, de [Cutrim dos Santos, 2021], utilizou imagens de satélite Landsat 8 e de referência RapidEye e técnicas de sensoriamento remoto para identificar áreas de garimpo na região do Tapajós, no Pará. O estudo destacou a importância de métodos para melhorar a resolução das imagens de satélite por meio de Redes Adversárias Generativas (GANs, especificamente SRGAN e ESRGAN), que, combinadas com a Rede Neural Convolucional U-Net, aprimoraram a detecção de regiões degradadas pelo garimpo, como clareiras ou superfícies de solo exposto, em áreas de difícil acesso. Os resultados demonstraram ganhos de até 15% nas métricas de detecção, alcançando 86% de F1-Score no melhor cenário (ESRGAN/U-Net) [Cutrim dos Santos, 2021].

Outro exemplo é o trabalho de conclusão de curso de [Lima, 2022], intitulado “Mapeamento das áreas de garimpo em terras indígenas Munduruku utilizando modelo baseado em conhecimento e integração multisensores”, que desenvolveu um modelo de classificação para identificação e mapeamento de áreas de garimpo em terras indígenas na Amazônia, com foco especial na Terra Indígena Munduruku, uma das mais afetadas pela mineração ilegal. O estudo proposto por ela apresenta uma abordagem baseada em conhecimento, utilizando imagens dos satélites Landsat 5, Landsat 8 e CBERS-4A para uma análise temporal dos anos de 2010, 2016, 2018 e 2021, caracterizando um estudo multisensor. Na modelagem, foram utilizados algoritmos de classificação supervisionada, como Random Forest (RF), Support Vector Machine (SVM) e Geographic Object-Based Image Analysis (GEOBIA), além de índices espectrais como Índice de Vegetação de Diferença Normalizada (NDVI) e Índice de Água de Diferença Normalizada (NDWI). O modelo final, baseado na integração desses conhecimentos, foi validado com um excelente Índice Kappa de 0,94 e Exatidão Global de 96,75%. Os resultados obtidos com a aplicação destes modelos mostraram um crescimento acelerado das áreas de garimpo, em que, de 2016 até 2021, a área minerada aumentou em mais de 936% [Lima, 2022].

Já no campo da inteligência artificial aplicada ao monitoramento ambiental na Amazônia, destaca-se a tese de doutorado de [Rodrigues, 2024], intitulada “Inteligência Artificial para Analisar o Desmatamento na Região Amazônica Brasileira”. O trabalho em questão propõe uma análise utilizando geoprocessamento, sensoriamento remoto e inteligência artificial para analisar o desmatamento na região Amazônica brasileira entre os anos de 2001 e 2022, onde o estudo utilizou imagens de satélite e dados do PRODES/INPE para classificar áreas segundo as classes de corte raso, queimadas, mineração e áreas de proteção ambiental, com foco nas regiões Altamira e São Félix do Xingu, no Pará. Foram aplicados e comparados os algoritmos K-Nearest Neighbors (KNN), Random Forest (RF) e Redes Neurais Convolucionais (RNC), sendo que este último modelo apresentou os melhores resultados em métricas de acurácia, precisão e F1-score. Embora a classe Mineração tenha apresentado a precisão mais baixa no RNC (69,04%), o modelo ainda assim superou o desempenho dos outros algoritmos para essa classe, destacando a capacidade da CNN em lidar com classes de difícil detecção [Rodrigues, 2024]. Tendo como principal contribuição a integração de dados espaciais com técnicas de aprendizado de máquina para mapeamento multiclasse de alterações ambientais, demonstrando o potencial da inteligência artificial para aprimorar a detecção de padrões complexos em imagens multitemporais da Amazônia. Embora o foco principal tenha sido o desmatamento como um todo, os métodos empregados e os resultados obtidos fornecem contribuições valiosas para diferentes abordagens mais específicas, como a proposta deste trabalho, voltada à detecção de garimpo.

Fora do Brasil, [Gallwey *et al.*, 2020] desenvolveram a primeira Rede Neural Convolucional U-Net multiespectral para a detecção automática de Mineração Artesanal e em Pequena Escala (ASM) na região Sul de Gana, utilizando imagens do satélite Sentinel-2. O modelo utilizou 10 bandas espectrais (incluindo as bandas SWIR) para aprender as características espaciais e espectrais do garimpo. O método

Tabela 1. Comparativo de Trabalhos Relacionados sobre Detecção de Garimpo e Desmatamento.

Autor / Ano	Área / Região	Objetivo	Modelo(s)	Dados / Recorte	Resultados	Contribuições
Rodrigues [2024]	Municípios de Altamira e São Félix do Xingu (PA), na Amazônia Brasileira.	Análise de desmatamento (corte raso, queimadas, mineração) via classificação de imagens de satélite (CBERS-4, 2001-2022).	K-Vizinhos Mais Próximos (KNN), Floresta Aleatória (RF) e Rede Neural Convolucional (RNC).	Imagens do satélite CBERS-4 (Sensor WFI, 12 bandas espectrais, resolução 64m) e bases de dados do PRODES, de 2001 a 2022.	RNC (Acurácia: 97,4%, Kappa: 80,4%) superior; Mineração (Precisão RNC: 69,04%, F-Score RNC: 81,7%, Precisão KNN: 54,76% e Precisão RF: 52,38%).	Demonstra superioridade da RNC na classificação de desmatamento e mineração, tendo maior complexidade em imagens espectrais.
Cutrim dos Santos [2021]	Região de Integração do Tapajós (PA), Amazônia Brasileira.	Desenvolver metodologia com GANs (SR) para aprimorar imagens Landsat 8 e melhorar detecção de garimpo com U-Net (2014).	Redes Adversárias de Super-Resolução (SRGAN, ESRGAN) para melhoramento da imagem, seguidas de Rede Neural Convolucional U-Net para segmentação e detecção de garimpo.	Imagens de satélite Landsat 8 (baixa resolução, 30m) e RapidEye (alta resolução, 5m) utilizadas como referência, datadas em 2014.	Ganhos de até 15% na detecção de garimpo. Melhor modelo (ESRGAN BS2 + U-Net): ACC: 86%; SENS: 80%; PREC: 94%; F1-Score: 86%. (F1 Baseline original: 76%).	Super-Resolução (ESRGAN) aprimora significativamente a detecção de garimpo com U-Net, especialmente para garimpos menores.
Lima [2022]	Terra Indígena Munduruku (PA), região do Tapajós.	Mapear e analisar a expansão de garimpo (2010-2021) em TI Munduruku usando Modelo Baseado em Conhecimento e multissensores.	Modelo Baseado em Conhecimento (Modelo 5), integrando: Random Forest (RF), Support Vector Machine (SVM) e GEOBIA; e dados auxiliares (MapBiomias, PRODES, NDVI).	Imagens Landsat 5, Landsat 8 e CBERS 04A (multissensores), no período de 2010, 2016, 2018 e 2021 (área de estudo e área piloto).	Modelo 5 (mais eficaz com RF e SVM) usados para classificação da classe Garimpo com dados do MapBiomias: Kappa: 0,94; Exatidão Global: 96,75% (2021).	Método de classificação baseado em conhecimento eficaz para detecção multiclasse (incluindo garimpo), superando classificação pixel a pixel. Fornecendo dados robustos sobre a expansão acelerada do garimpo (936,6% entre 2016 e 2021).
Gallwey et al. [2020]	Sul de Gana, Craton Oeste Africano (6 milhões de hectares).	Desenvolver e validar CNN multiespectral (U-Net) para detecção automática de Garimpo Artesanal (ASM) e desmatamento com Sentinel-2 (2015-2019).	Rede Neural Convolucional U-Net (multiespectral, 10 canais), comparada a classificadores tradicionais (Random Forest, Multi-Layer Perceptron, SAM).	Imagens multiespectrais Sentinel-2 (10 bandas, 10m/20m de resolução) sobre o sul de Gana, cobrindo o período de 2015 a 2019 (4 anos).	Média IoU de 0.87 (vistos) e 0.83 (não vistos); Mine Class IoU de 0.86 (vistos) e 0.82 (não vistos); erros de omissão/comissão abaixo de 8%.	Primeira CNN multiespectral para detecção de ASM em Sentinel-2. Com forte capacidade de generalização e escalabilidade para monitoramento nacional.
Camalan et al. [2022]	Madre de Dios (MDD), Peru (Hotspot de Garimpo Aluvial na Amazônia). Testes out-of-sample em Venezuela, Indonésia e Mianmar.	Detectar e categorizar mudanças em lagoas de Garimpo Aluvial (ASGM) comparando Deep Learning (E-ReCNN) e Semi-Supervisionados (SVM-STV) com Sentinel-2 (2019, 2021).	E-ReCNN (Extended Recurrent Convolutional Neural Network - Combinação de CNN e LSTM) para detecção de mudanças. Comparado com SVM-STV (Semi-Supervisionado).	Imagens Sentinel-2 multiespectrais, em pares bi-temporais (2019 e 2021). O melhor desempenho foi obtido com o set de 6 canais (RGB, NIR, SWIR1 e SWIR2) após Histogram Matching.	E-ReCNN (6 canais + Histogram Matching): Kappa: 0,92; Jaccard: 0,88; F1-Score: 0,88. Generalização out-of-sample com: Kappa: 0,90; F1-Score: 0,77.	Modelo Deep Learning (E-ReCNN) preciso e escalável para detectar mudanças finas em lagoas de garimpo. Evidenciando que o pré-processamento (Histogram Matching) é essencial para ganhos significativos no F1-Score (de 0,71 para 0,88).
Boaro et al. [2021]	Amazônia Brasileira (destaque para a Terra Indígena Munduruku).	Segmentação semântica de áreas de exploração de ouro para monitoramento e fiscalização ambiental.	Rede Neural Convolucional U-Net (backbone ResNet-34).	Imagens de alta resolução do satélite RapidEye.	Acurácia: 98,34%; Precisão: 91,29%; F1-Score: 0,76.	Demonstra a viabilidade da U-Net com imagens de alta resolução para automatizar o mapeamento, reduzindo a dependência de inspeção manual baseada apenas em reflectância.

demonstrou desempenho superior aos classificadores tradicionais, alcançando um Mine Class IoU (Intersection Over Union) de 0,86 em dados vistos e 0,82 em dados não vistos, destacando a forte capacidade de generalização da CNN e confirmando que esta metodologia é altamente adequada para o mapeamento e monitoramento em larga escala do garimpo [Gallwey et al., 2020].

No contexto da Amazônia Internacional, [Camalan et al., 2022] abordaram o desafio de detectar mudanças em lagoas de Garimpo Aluvial em Pequena Escala (ASGM) na região de Madre de Dios, no Peru, utilizando séries temporais de imagens Sentinel-2. Os autores propuseram o modelo E-ReCNN (Extended Recurrent Convolutional Neural Network), que combina a capacidade espacial das CNNs com a análise temporal das LSTMs. O estudo demonstrou que o pré-processamento das imagens Sentinel-2 via Histogram Matching foi essencial, elevando o F1-Score de 0,71 para 0,88. O modelo mais eficaz (E-ReCNN, 6 canais) alcançou F1-Score de 0,88 e Jaccard (IoU) de 0,88 para a detecção de mudanças na região focal. Adicionalmente, o E-ReCNN demonstrou forte capacidade de generalização em regiões out-of-sample (mantendo Kappa de 0,90), confirmando a adequação de modelos profundos e multitemporais para o monitoramento preciso e escalável da dinâmica do garimpo aluvial na Amazônia [Camalan et al., 2022].

Recentemente, Boaro et al. [2021] desenvolveram um método baseado na arquitetura U-Net, utilizando um *backbone* ResNet-34, para segmentar áreas de exploração de ouro na Floresta Amazônica, incluindo sobreposições na Terra Indígena Munduruku. O estudo utilizou imagens de alta resolução do satélite RapidEye e alcançou métricas expressivas, com precisão de 91,29%, F1-Score de 0,76 e acurácia global de 98,34%. Os autores enfatizaram que a identificação automática por meio de redes convolucionais minimiza a necessidade de inspeção manual exaustiva, superando as abordagens tradicionais que dependem exclusivamente de valores brutos de reflectância.

De forma geral, os trabalhos analisados evidenciam uma transição de métodos baseados em regras, atributos espectrais e classificadores tradicionais para abordagens baseadas em Redes Neurais. Estudos nacionais demonstram ganhos progressivos ao incorporar CNNs e técnicas de super-resolução ou integração multisensor, porém frequentemente dependem de resoluções específicas, pré-processamentos complexos ou abordagens multiclasse com forte especialização regional [Cutrim dos Santos, 2021; Lima, 2022; Rodrigues, 2024]. Em paralelo, estudos internacionais confirmam o potencial de arquiteturas convolucionais multiespectrais e temporais para o monitoramento escalável do garimpo, alcançando elevados índices de acurácia e capacidade de generalização [Gallwey et al., 2020; Camalan et al., 2022]. Ainda assim, observa-se uma lacuna na disponibilização de pipelines reproduzíveis e datasets públicos em larga escala focados especificamente na detecção binária de garimpo na Amazônia. Nesse contexto, o presente trabalho contribui ao combinar um fluxo de coleta e curadoria de dados reproduzível, um conjunto de dados balanceado e a avaliação sistemática de modelos clássicos e profundos, reforçando o papel das CNNs como ferramenta robusta para o monitoramento ambiental.

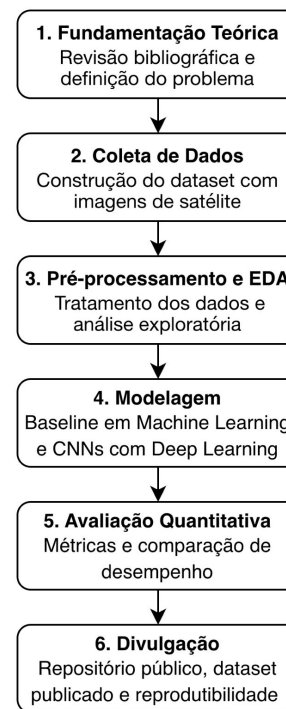


Figura 1. Diagrama das etapas do método.

3 Metodologia

A metodologia adotada é organizada em seis macro-etapas interdependentes, abrangendo desde a fundamentação teórica até a divulgação dos resultados, conforme ilustrado na Figura 1. Essa estrutura foi concebida para garantir reprodutibilidade, consistência experimental e comparação sistemática entre diferentes abordagens de modelagem.

A primeira etapa consistiu na revisão da literatura, com foco em aprendizado profundo, visão computacional aplicada ao sensoriamento remoto e estudos sobre os impactos ambientais do garimpo na Amazônia. Essa análise permitiu a definição do problema, a escolha das técnicas empregadas e a comparação com trabalhos relacionados.

Na sequência, realizou-se a coleta de dados e a construção do dataset. Foram selecionadas regiões da Amazônia contendo áreas com e sem garimpo, priorizando zonas de mineração ilegal em relação a unidades de conservação e terras indígenas. A coleta baseou-se em imagens de satélite de acesso aberto e em bases cartográficas públicas, em especial os dados do MapBiomias e os polígonos de garimpo da RAISG [MapBiomias, 2023; RAISG, 2025].

A terceira etapa compreendeu o pré-processamento dos dados, incluindo a aplicação de máscaras de nuvens e sombras, a geração de mosaicos temporais e o recorte das imagens em chips. Em paralelo, conduziu-se uma Análise Exploratória de Dados (EDA) para avaliar a qualidade do conjunto de dados e investigar a separabilidade entre classes por meio de descritores espectrais e estruturais.

Na etapa de modelagem, foram inicialmente treinados modelos clássicos de aprendizado de máquina utilizando atributos tabulares, com o objetivo de estabelecer um *baseline*. Em seguida, avançou-se para modelos de aprendizado profundo baseados em Redes Neurais Convolucionais, incluindo arquiteturas treinadas do zero e modelos com transferência de aprendizado, permitindo a exploração de padrões espaciais e

espectrais mais complexos [Breiman, 2001; Goodfellow et al., 2016].

A avaliação quantitativa foi realizada a partir de subconjuntos de treino, validação e teste, utilizando métricas tradicionais de classificação binária, como precisão, revocação, F1-score, acurácia e AUC [Sokolova and Lapalme, 2009]. Por fim, todos os códigos, pesos de modelos e artefatos experimentais foram disponibilizados em repositório público, assegurando a reprodutibilidade e facilitando a continuidade do trabalho por outros pesquisadores.

3.1 Coleta de Dados

A coleta de dados foi realizada integralmente na plataforma Google Earth Engine (GEE), que permite o processamento eficiente de grandes volumes de imagens de satélite diretamente em ambiente de nuvem, sendo amplamente utilizada em estudos de sensoriamento remoto em larga escala [Gorelick et al., 2017]. Sendo elaborada em um fluxo contendo 6 principais etapas, conforme ilustrado na Figura 2.

A área de estudo foi determinada a partir da sobreposição de regiões com ocorrência conhecida de garimpo sobre áreas sem mineração. Para isso foi utilizada a coleção 9 do MapBiomas no GEE, de modo a garantir diversidade de cenários ambientais [MapBiomas, 2023]. Fazendo um recorte geográfico que prioriza zonas da Amazônia Legal com presença de frentes de garimpo sobre territórios protegidos, como unidades de conservação e terras indígenas, além de áreas de floresta densa e corpos d’água preservados. A Figura 3 apresenta a região selecionada, com os polígonos de mineração da RAISG sobrepostos ao mosaico de imagens de satélite [RAISG, 2025].

Foram utilizadas imagens multiespectrais da coleção Sentinel-2 Nível 2A, que fornece refletância de superfície com resolução espacial de até 10 metros [European Space Agency, 2025]. Devido à elevada incidência de nuvens na região amazônica, aplicou-se o algoritmo *s2cloudless* para a detecção probabilística de nuvens e sombras, resultando em máscaras mais precisas do que abordagens baseadas em limiares fixos [Sentinel Hub, 2024]. Após a aplicação das máscaras, foram gerados mosaicos temporais por meio da mediana dos pixels válidos, estratégia que reduz interferências atmosféricas residuais e variabilidade sazonal [Qiu et al., 2019].

As bandas espectrais B2 (Azul), B3 (Verde), B4 (Vermelho), B8 (Infravermelho Próximo), B11 e B12 (Infravermelho de Ondas Curtas) foram padronizadas para refletância de superfície, garantindo consistência radiométrica para o cálculo de índices espectrais e para o treinamento dos modelos.

Como etapa complementar de validação, imagens dos satélites Landsat-8 e Landsat-9 também foram analisadas, permitindo a verificação cruzada da presença de cicatrizes de garimpo em datas próximas, apesar da resolução espacial inferior de 30 metros [U.S. Geological Survey, 2022]. Essa verificação cruzada contribuiu para reduzir a inclusão de inconsistências no conjunto de dados.

Por fim, os mosaicos processados foram exportados para o Google Drive, e uma grade regular de células com aproximadamente 2,56 km de lado foi gerada para orientar o recorte sistemático dos chips utilizados nas etapas subsequentes. Esse procedimento assegura a reprodutibilidade do processo de



Figura 2. Diagrama das etapas da coleta de dados.

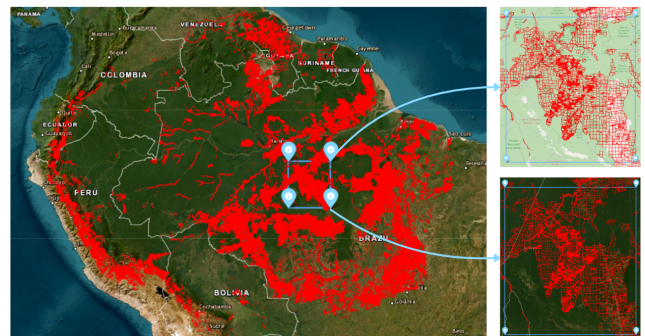


Figura 3. Região selecionada da área de estudo com sobreposição dos polígonos de mineração da RAISG.

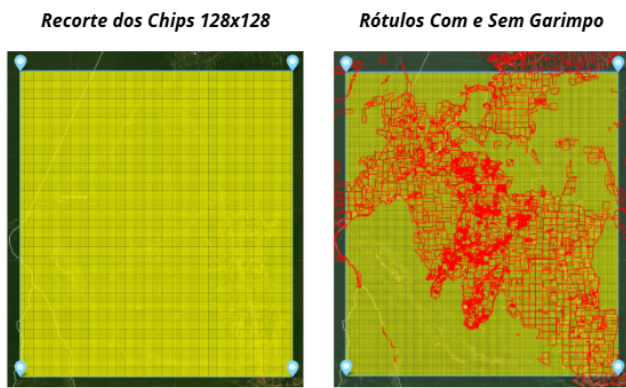


Figura 4. Região selecionada da área de estudo com sobreposição dos recortes (*chips*) utilizados na construção do dataset.

coleta e facilita sua reaplicação a diferentes regiões ou janelas temporais [Gorelick et al., 2017].

3.2 Construção do Dataset

A construção do dataset foi realizada em Python a partir dos mosaicos exportados do Google Earth Engine e dos dados vetoriais de referência. O objetivo desta etapa foi transformar imagens de satélite de grande extensão em pequenos recortes (*chips*) rotulados, um formato amplamente adotado no treinamento de Redes Neurais Convolucionais aplicadas à visão computacional.

Inicialmente, os polígonos de garimpo disponibilizados pela RAISG foram reprojatados para o mesmo sistema de coordenadas dos mosaicos, assegurando consistência geométrica nas operações espaciais. Em seguida, definiu-se uma grade regular de recortes diretamente sobre as imagens, composta por janelas de 128×128 pixels. Considerando a resolução espacial de 10 metros do Sentinel-2, desse modo, cada chip cobre aproximadamente 1,28 km², preservando contexto suficiente para distinguir clareiras de mineração, margens de rios e plumas de sedimentos. A Figura 4 ilustra a disposição desses recortes sobre a área de estudo.

A rotulagem foi realizada de forma automática a partir da interseção espacial entre cada chip e os polígonos de garimpo. Um recorte foi rotulado como positivo (*com_garimpo*) quando mais de 5% de sua área coincidia com um polígono de mineração; caso contrário, foi rotulado como negativo (*sem_garimpo*). Esse limiar foi adotado para reduzir ruídos decorrentes de interseções nas margens, ao mesmo tempo em que preserva a sensibilidade para capturar frentes de garimpo ainda em estágios iniciais.

As imagens foram armazenadas em formato PNG, utilizando uma composição RGB das bandas B4 (vermelho), B3 (verde) e B2 (azul). Paralelamente, foi gerado um arquivo de manifesto em formato CSV contendo os metadados de cada amostra, incluindo o caminho do arquivo, o rótulo atribuído, as coordenadas geográficas do centróide e a porcentagem exata de sobreposição com áreas de garimpo. Esse manifesto permite rastrear cada recorte até sua posição original no mapa, facilitando auditorias, análises posteriores e a reprodutibilidade do processo.

A divisão final do conjunto de dados em treinamento e teste foi realizada de forma estratificada, mantendo a proporção entre as classes, com 80% das amostras destinadas ao treinamento e 20% reservadas para teste. Para mitigar o

risco de vazamento espacial (*spatial leakage*), o processo de amostragem foi projetado sobre uma grade regular de grande extensão geográfica na Amazônia Legal. Isso garantiu que chips adjacentes fossem tratados como amostras independentes no manifesto, e a vasta escala da área de estudo permitiu que o modelo fosse exposto a uma diversidade de contextos ambientais, reduzindo a dependência de correlações espaciais locais.

A Tabela 2 apresenta a distribuição quantitativa final das amostras, evidenciando que o dataset resultante é naturalmente balanceado, devido ao recorte geográfico da área de estudo, que foi intencionalmente delimitado para englobar zonas com alta densidade de mineração mapeadas pela RAISG. Garantindo uma proporção com quantidades muito próximas de imagens com e sem garimpo, o que dispensou a aplicação de técnicas artificiais de balanceamento nesta etapa.

Tabela 2. Distribuição das imagens nos conjuntos de treinamento e teste.

Conjunto	Com Garimpo	Sem Garimpo	Total
Treino	44.432	44.834	89.266
Teste	11.109	11.209	22.318
Total	55.541	56.043	111.584

Ao final desse processo, obteve-se um conjunto de dados com mais de 111 mil imagens rotuladas e rastreáveis, totalizando aproximadamente 2,6 GB. Esse dataset foi utilizado diretamente nos experimentos de aprendizado profundo apresentados nas seções seguintes e pode ser reproduzido para outras regiões ou períodos apenas ajustando os dados de entrada no pipeline.

3.3 Análise Exploratória dos Dados (EDA)

Antes de submeter o conjunto de dados ao treinamento das redes neurais profundas, foi conduzida uma Análise Exploratória de Dados (EDA) com dois objetivos principais: (i) validar a integridade dos dados gerados e (ii) avaliar a separabilidade das classes utilizando descritores de baixo custo computacional.

Devido ao volume massivo de dados (mais de 111 mil imagens), implementou-se uma rotina em Python para a extração paralela, em CPU, de estatísticas descritivas de cada chip. Foram analisados atributos espectrais, como o brilho médio e o índice de vegetação ExG (*Excess of Green*), e atributos estruturais, como a variância do Laplaciano (indicador de textura e nitidez) e a energia de borda obtida pelo operador Sobel.

A análise inicial concentrou-se nas características de cor e luminosidade. Começando pela análise do índice de vegetação ExG, apresentada nos gráficos A e B da Figura 5, revelando uma sobreposição considerável entre as classes. Embora as áreas de garimpo apresentem, em média, valores ligeiramente menores de ExG, a elevada variância indica que a ausência de cobertura vegetal, isoladamente, não é suficiente para discriminar o problema, uma vez que nuvens, rios e estradas também produzem valores baixos desse índice.

Em contrapartida ao observar os gráficos C e D da Figura 5, as áreas de garimpo tendem a apresentar valores de brilho médio superiores às áreas de não garimpo. Esse comportamento corrobora a premissa teórica de que o solo exposto

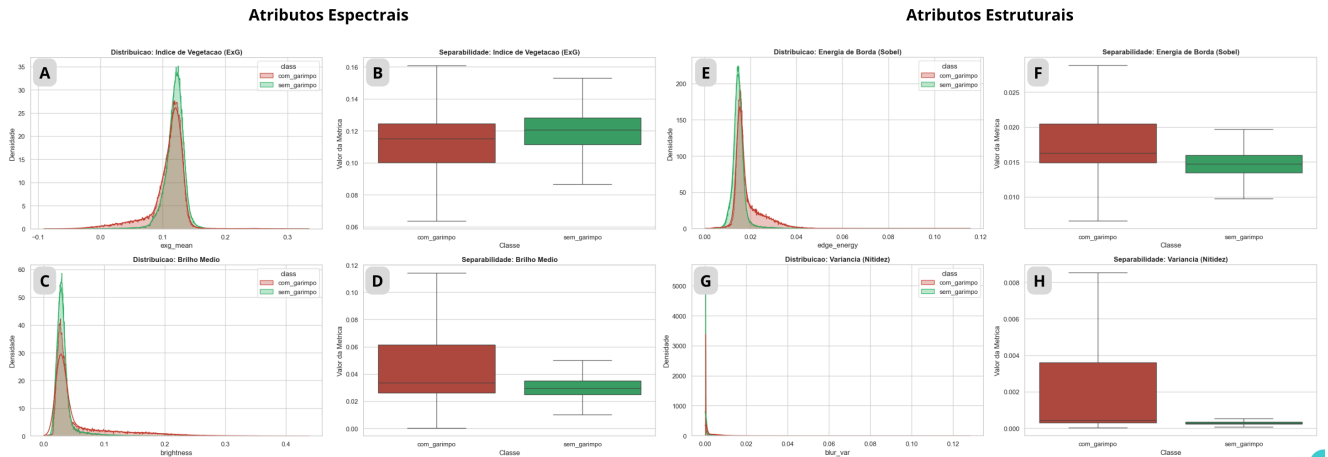


Figura 5. Gráficos da Análise Exploratória de Dados (EDA), incluindo distribuições e boxplots dos atributos espectrais (brilho médio e ExG) e estruturais (variância do Laplaciano e energia de borda).




Figura 6. Distribuição da densidade de garimpo no conjunto de dados.

e as águas turvas possuem maior reflectância global do que a floresta densa ou corpos d’água preservados.

Os resultados mais expressivos emergem da análise de atributos estruturais. Os gráficos G e H relativos à variância do Laplaciano na Figura 5 evidenciam que imagens de garimpo são significativamente mais rugosas e caóticas, apresentando maior variância em comparação às imagens de controle. A diferença relativa entre as médias das classes supera 120%, indicando que a textura é um forte discriminador ao capturar a complexidade visual associada às cavas e ao revolvimento do solo.

De forma complementar, os gráficos E e F de energia de borda (Sobel), também apresentados na Figura 5, mostram que áreas de garimpo exibem valores significativamente mais elevados desse atributo. Enquanto a floresta preservada tende a apresentar transições suaves de cor, o garimpo é caracterizado por mudanças abruptas entre solo exposto, água e vegetação, resultando em gradientes intensos. Esses resultados reforçam que atributos estruturais são tão ou mais relevantes que atributos puramente espectrais para a distinção entre as classes.

Além dos atributos visuais, avaliou-se a consistência semântica do dataset por meio da fração de área degradada (*overlap ratio*) presente em cada chip. A Figura 6 mostra que a maior parte das amostras positivas concentra-se na faixa de alta densidade (> 75%), totalizando mais de 51 mil imagens. As categorias de ruído (> 0% a 5%) e baixa densidade (5% a 25%) apresentam frequências significativamente menores, indicando que o conjunto de dados é predominantemente composto por frentes de garimpo consolidadas, com uma parcela reduzida de exemplos de transição ou vestígios sutis.

Com a validação da qualidade dos dados e a identificação de atributos estatísticos discriminantes, especialmente aqueles relacionados à textura e à estrutura, surge a questão central: até que ponto esses descritores simples são suficientes para automatizar a detecção com alta precisão? Para responder a essa pergunta e mensurar o ganho efetivo proporcionado pelo Aprendizado Profundo, a próxima seção estabelece um *baseline* utilizando modelos tradicionais de Aprendizado de Máquina treinados exclusivamente sobre essas informações tabulares.

3.4 Baseline com Algoritmos Clássicos de Aprendizado de Máquina

Antes da aplicação de Redes Neurais Convolucionais, foi estabelecida um *baseline* de desempenho com algoritmos clássicos de aprendizado de máquina. O objetivo desta etapa foi avaliar se a detecção de garimpo poderia ser realizada de forma satisfatória utilizando apenas descritores estatísticos globais, sem a incorporação explícita de contexto espacial.

Os experimentos foram conduzidos em Python utilizando a biblioteca scikit-learn. O vetor de características foi composto por quatro atributos extraídos de cada imagem: índice de vegetação ExG, brilho médio, energia de borda (Sobel) e variância do Laplaciano, utilizada como medida de nitidez. A variável alvo correspondeu a uma classificação binária, distinguindo imagens “Sem Garimpo” e “Com Garimpo”. A divisão entre os conjuntos de treinamento e teste seguiu rigorosamente o manifesto do dataset, garantindo que os modelos não tivessem acesso aos dados de teste durante a fase de treinamento e permitindo comparabilidade direta com os experimentos subsequentes.

Foram avaliados dois modelos com naturezas distintas. A Regressão Logística foi empregada como modelo linear de referência, com normalização dos atributos via StandardScaler, devido à sensibilidade desse método à escala das variáveis. O Random Forest foi selecionado por sua capacidade de modelar relações não lineares, sendo configurado com o valor padrão dos seus hiperparâmetros.

Os resultados obtidos são apresentados na Tabela 3. A Regressão Logística apresentou baixo desempenho, com revocação de apenas 0,43 para a classe “Com Garimpo”, indicando uma elevada taxa de falsos negativos. Esse comportamento

evidencia a dificuldade de um classificador linear em separar adequadamente áreas degradadas e não degradadas com base apenas nos descritores considerados.

O Random Forest apresentou melhora significativa em relação ao modelo linear, alcançando precisão de 0,73, revocação de 0,70 e F1-score de 0,72 para a classe de interesse, além de acurácia global de 72% e AUC de 0,80. Ainda assim, esse desempenho revela um contexto importante, aproximadamente 30% das amostras permanecem classificadas incorretamente, refletindo limitações estruturais da abordagem.

Essas limitações decorrem da natureza dos modelos baseados em atributos tabulares, que processam as imagens como conjuntos de estatísticas globais e ignoram sua organização geométrica e contexto espacial. Embora atributos estruturais, como variância do Laplaciano e energia de borda, tenham se mostrado mais relevantes do que atributos puramente espectrais, em concordância com a Análise Exploratória de Dados, eles são insuficientes para capturar a complexidade das cicatrizes de garimpo. Esse cenário fundamenta a necessidade de empregar Redes Neurais Convolucionais, capazes de aprender representações espaciais hierárquicas diretamente a partir das imagens, conforme apresentado na próxima seção.

3.5 Detecção de Garimpo com Redes Neurais Convolucionais

Diante das limitações observadas nos modelos baseados em descritores estatísticos globais, avançou-se para a aplicação de Redes Neurais Convolucionais (CNNs), capazes de aprender representações espaciais hierárquicas diretamente a partir das imagens. Diferentemente dos métodos clássicos, as CNNs exploram o contexto geométrico e a organização espacial dos pixels, permitindo capturar padrões complexos associados às frentes de garimpo, como cavas, plumas de sedimentos e infraestruturas auxiliares [Goodfellow et al., 2016].

Os experimentos envolveram duas arquiteturas com níveis distintos de complexidade. Inicialmente, foi implementada uma CNN simples (*Simple CNN*), treinada do zero, com o objetivo de validar o pipeline de treinamento e avaliar se uma arquitetura rasa seria capaz de superar o baseline estatístico. Em seguida, adotou-se a arquitetura EfficientNet-B0, explorada por meio de *transfer learning*, técnica amplamente utilizada para reduzir o custo computacional e melhorar o desempenho em domínios com dados limitados [Tan and Le, 2019].

3.5.1 Configuração Experimental e Pré-processamento

Os modelos foram implementados utilizando a biblioteca PyTorch e treinados em ambiente de nuvem equipado com GPU NVIDIA T4. O treinamento foi realizado com tamanho de *batch* de 32 e a função de perda utilizada foi a *CrossEntropyLoss*. Como otimizador, empregou-se o Adam, com uma taxa de aprendizado inicial de 1×10^{-3} . O conjunto de dados foi dividido em três subconjuntos disjuntos: treino (71.412 imagens), validação (17.854 imagens) e teste (22.318 imagens), mantendo o balanceamento entre as classes. O conjunto de validação foi utilizado exclusivamente para o monitoramento da convergência e aplicação de *early stopping*, estratégia fundamental para prevenir o sobreajuste em redes profundas [Goodfellow et al., 2016].

No pré-processamento, as imagens originais de 128×128 pixels foram redimensionadas para 224×224 pixels a fim de adequar o formato de entrada à EfficientNet-B0, cuja arquitetura foi originalmente projetada e pré-treinada nessa resolução espacial [Tan and Le, 2019]. Embora o redimensionamento não introduza novas informações visuais, essa etapa é necessária para garantir a compatibilidade estrutural com o modelo e permitir o uso efetivo de *transfer learning*, preservando a correspondência entre os filtros convolucionais aprendidos no ImageNet e os padrões presentes nas imagens de entrada [Tan and Le, 2019].

Adicionalmente, técnicas de *data augmentation* foram aplicadas exclusivamente ao conjunto de treinamento, incluindo rotações aleatórias, espelhamentos horizontais e verticais, além de variações controladas de brilho e contraste. Essas transformações visam aumentar artificialmente a diversidade do conjunto de dados, reduzindo o risco de *overfitting* e incentivando o modelo a aprender representações mais invariantes a mudanças geométricas e fotométricas, o que contribui para uma melhor capacidade de generalização [Shorten and Khoshgoftaar, 2019]. Para os conjuntos de validação e teste, foram aplicadas apenas operações determinísticas de redimensionamento e normalização, assegurando uma avaliação justa e reproduzível do desempenho do modelo.

3.5.2 Arquiteturas Avaliadas

A *Simple CNN*, nome atribuído a uma rede construída com a biblioteca PyTorch, foi composta por três camadas convolucionais seguidas de operações de *max-pooling* e camadas totalmente conectadas, sendo projetada para aprender bordas, texturas e padrões geométricos básicos. Esse tipo de arquitetura rasa é frequentemente utilizado como linha intermediária de comparação para avaliar os ganhos efetivos proporcionados por arquiteturas profundas e por técnicas de transferência de aprendizado [Goodfellow et al., 2016].

A EfficientNet-B0 foi utilizada com pesos pré-treinados no ImageNet, seguindo uma estratégia em duas etapas. Na primeira fase, as camadas convolucionais foram congeladas e apenas o classificador final foi treinado para o problema binário, explorando filtros genéricos previamente aprendidos. Na segunda fase, realizou-se o *fine-tuning* de toda a rede com uma taxa de aprendizado reduzida, para 1×10^{-4} , permitindo a adaptação progressiva dos filtros às características específicas do bioma amazônico. O critério de *early stopping* foi configurado com uma paciência de 10 épocas, monitorando a redução da perda no conjunto de validação para evitar o sobreajuste. Essa abordagem tem se mostrado eficaz em aplicações de sensoriamento remoto e visão computacional ambiental [Tan and Le, 2019; Camalan et al., 2022].

4 Resultados e Discussão

4.1 Dinâmica de Treinamento e Convergência

A análise da dinâmica de treinamento fornece indícios importantes sobre a estabilidade e a capacidade de generalização das arquiteturas avaliadas. A Figura 7 apresenta o histórico consolidado de acurácia e perda ao longo das épocas de treinamento.

A *Simple CNN* apresentou aprendizado inicial rápido;

Tabela 3. Métricas dos algoritmos de Regressão Logística e Random Forest no baseline.

Modelo	Classe	Precisão	Revocação	F1-Score	Acurácia	AUC
Regressão Logística	Sem Garimpo	0,60	0,87	0,71	0,65	0,73
	Com Garimpo	0,76	0,43	0,55		
Random Forest	Sem Garimpo	0,72	0,74	0,73	0,72	0,80
	Com Garimpo	0,73	0,70	0,72		

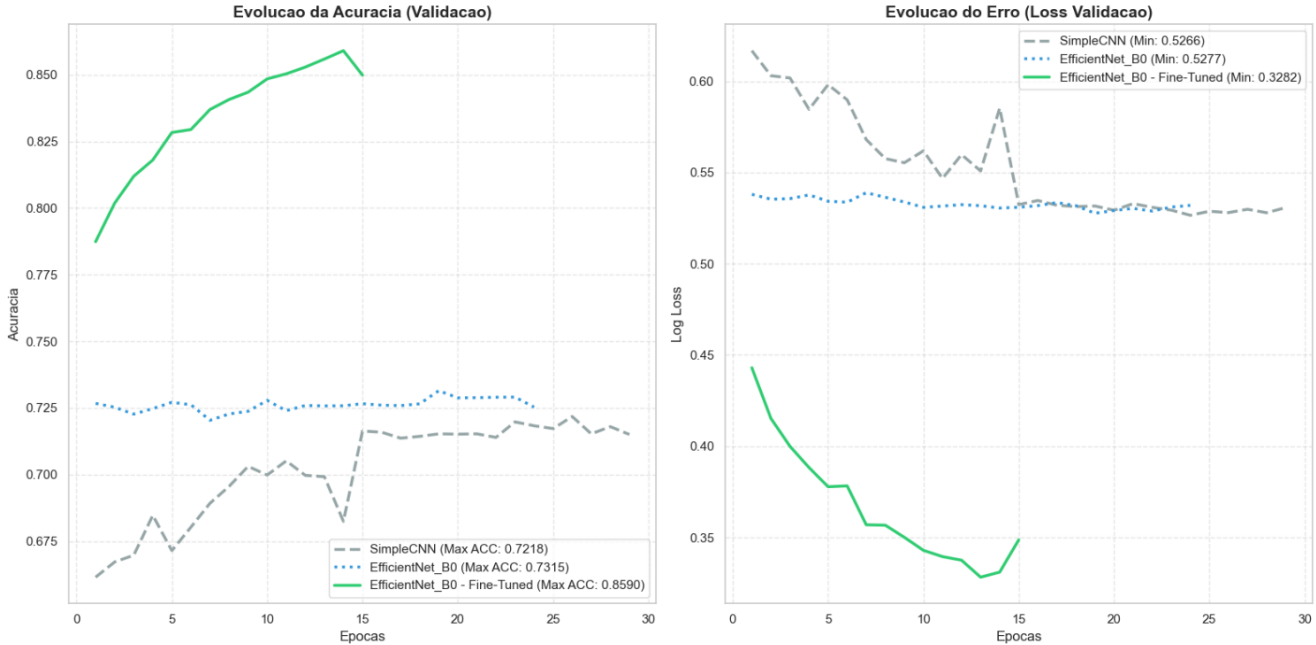


Figura 7. Evolução da acurácia e da função de perda no conjunto de validação para as arquiteturas *Simple CNN*, *EfficientNet-B0* e *EfficientNet-B0 Fine-Tuned*.

porém, estabilizou-se precocemente, atingindo uma acurácia próxima a 72%. O mecanismo de *early stopping* interrompeu o treinamento na época 29. Para a *EfficientNet-B0*, a fase de congelamento do backbone durou 10 épocas, seguida pelo processo de ajuste fino até a convergência final. Isso indica que a arquitetura rasa encontrou um limite estrutural para modelar a complexidade visual associada às frentes de garimpo. Esse comportamento é consistente com observações da literatura, que apontam dificuldades de redes convolucionais pouco profundas em cenários ambientais altamente heterogêneos [Goodfellow et al., 2016].

Em contraste, a *EfficientNet-B0* evidenciou a eficácia da estratégia de transferência de aprendizado em duas etapas. Na fase inicial, com o *backbone* congelado, a rede convergiu rapidamente para um patamar próximo a 73% de acurácia. Contudo, o ganho mais expressivo ocorreu durante a fase de *fine-tuning*, quando o descongelamento das camadas, aliado a uma taxa de aprendizado reduzida, resultou em uma queda consistente da função de perda e em um aumento substancial da acurácia, atingindo aproximadamente 85,6%. Esse comportamento indica que o ajuste fino permitiu à rede especializar seus filtros para as características específicas do bioma amazônico, sem apresentar sinais severos de sobreajuste [Tan and Le, 2019].

4.2 Avaliação Quantitativa e Comparação com o Baseline

A avaliação final foi conduzida sobre um conjunto de teste independente contendo 22.318 imagens, igualmente balan-

ceadas entre as classes “Com Garimpo” e “Sem Garimpo”. A Tabela 4 sintetiza as métricas obtidas pelas arquiteturas convolucionais e permite a comparação direta com o baseline estatístico apresentado na seção anterior.

A *Simple CNN* apresentou desempenho estatisticamente equivalente ao do Random Forest, com acurácia em torno de 73% e AUC de aproximadamente 0,81. Esse resultado sugere que, embora a introdução de convoluções permita explorar contexto espacial local, uma arquitetura rasa treinada do zero não é suficiente para superar as limitações impostas pela complexidade visual do cenário amazônico.

Por outro lado, a *EfficientNet-B0* submetida ao processo de *fine-tuning* apresentou um salto expressivo de desempenho. A acurácia global atingiu 85,92%, representando um ganho de aproximadamente 13 pontos percentuais em relação ao baseline e à *Simple CNN*. Ainda mais relevante para aplicações de monitoramento ambiental, a AUC alcançou 0,9371, indicando elevada capacidade de discriminação independentemente do limiar de decisão, característica desejável em sistemas de alerta ambiental [Sokolova and Lapalme, 2009].

4.3 Discussão dos Resultados

Os resultados obtidos sustentam a hipótese central deste trabalho de que métodos baseados em atributos estatísticos globais, assim como arquiteturas convolucionais rasas, apresentam limitações ao lidar com a complexidade visual associada ao garimpo na Amazônia. O desempenho observado para essas abordagens, com acurácia em torno de 72% a 73%, é compatível com resultados reportados em estudos que utilizam descritores globais e classificadores tradicionais aplicados a

Tabela 4. Métricas dos algoritmos de CNN: *Simple CNN* e *EfficientNet-B0 (Fine-Tuned)*.

Modelo	Acurácia	AUC	F1-Score (Macro)	Precisão	Revocação
<i>Simple CNN</i>	0,73	0,81	0,73	0,74	0,73
<i>EfficientNet-B0 (Fine-Tuned)</i>	0,86	0,94	0,86	0,86	0,86

imagens de satélite, especialmente em cenários ambientais heterogêneos [Rodrigues, 2024].

Esse comportamento está relacionado à dificuldade desses modelos em capturar simultaneamente informações de textura, forma e organização espacial. Mesmo com a inclusão de atributos estruturais, como variância do Laplaciano e energia de borda, a representação dos dados permanece simplificada. Sendo essa a principal limitação de métodos baseados apenas em características de pixels, pois não analisam o contexto topológico e a geometria de vizinhança, enfrentando dificuldades para distinguir alvos com assinaturas espectrais semelhantes. O que resulta em confusões frequentes entre áreas de garimpo, bancos de areia naturais, rios barrentos, solo exposto, sombras e regiões parcialmente encobertas por nuvens, conforme observado também em análises exploratórias e em abordagens clássicas de sensoriamento remoto [Molina, 2023].

Em contrapartida, o uso de arquiteturas convolucionais mais profundas, aliado à transferência de aprendizado, levou a um ganho significativo de desempenho. A *EfficientNet-B0* superou os modelos tradicionais principalmente por conta da sua capacidade de extrair hierarquias de características espaciais complexas. Assim, a *EfficientNet-B0* com *fine-tuning* alcançou uma acurácia de 85,92% e AUC de 0,9371, evidenciando uma maior capacidade de extração de padrões espaciais relevantes ao identificar padrões geométricos e texturais específicos das cicatrizes de mineração, como a forma das cavas e o arranjo das plumas de sedimentos, características difíceis de serem identificadas pelas abordagens estatísticas globais. Resultados dessa ordem de grandeza são consistentes com trabalhos recentes que aplicam Redes Neurais Convolucionais para a detecção de mineração e desmatamento em imagens de satélite, tanto em estudos nacionais quanto internacionais [Gallwey et al., 2020; Camalan et al., 2022].

Cabe destacar que estudos que reportam métricas superiores geralmente adotam configurações mais complexas, como segmentação pixel a pixel, uso de dados multiespectrais completos ou integração temporal explícita. Exemplos incluem o uso de super-resolução combinada a redes do tipo U-Net [Cutrim dos Santos, 2021] e arquiteturas recorrentes aplicadas a séries temporais multiespectrais [Camalan et al., 2022]. Nesse contexto, os resultados obtidos neste trabalho são coerentes com a proposta adotada, que se baseia em classificação binária a partir de imagens RGB e em um pipeline metodológico simplificado e reproduzível.

Além disso, a diferença de desempenho observada entre a *Simple CNN* e a *EfficientNet-B0* reforça a importância da profundidade da rede e do reaproveitamento de representações previamente aprendidas em grandes bases de dados. Esse comportamento está alinhado com achados consolidados da literatura sobre aprendizado profundo e transferência de aprendizado em visão computacional [Tan and Le, 2019; Goodfellow et al., 2016].

Dessa forma, os experimentos indicam que a combinação

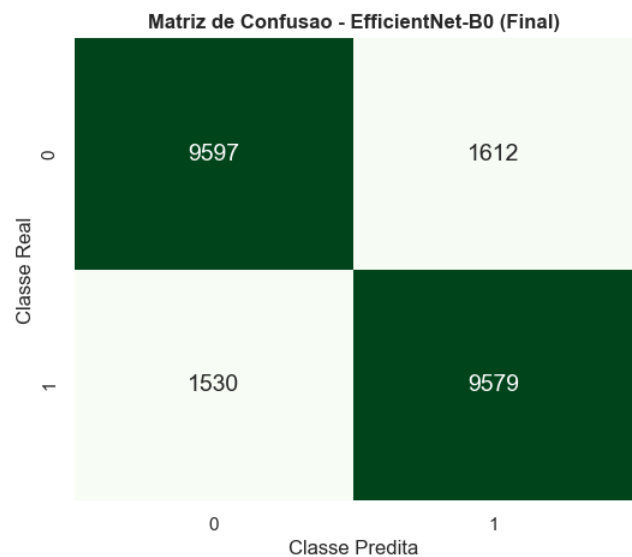


Figura 8. Matriz de confusão da arquitetura *EfficientNet-B0*



Figura 9. Exemplo qualitativo de Falso Positivo: área de desmatamento classificada como garimpo

entre um conjunto de dados bem curado, técnicas adequadas de *fine-tuning* e arquiteturas convolucionais eficientes permite superar as limitações observadas nos modelos mais simples. Os resultados obtidos sugerem que essa abordagem é adequada como base para sistemas de apoio ao monitoramento e à fiscalização do garimpo na Amazônia, conforme discutido em estudos recentes sobre aplicações operacionais de aprendizado profundo em sensoriamento remoto [Gallwey et al., 2020; Camalan et al., 2022].

4.4 Análise de Robustez e Erros

Para complementar a avaliação da *EfficientNet-B0*, a Figura 8 apresenta a matriz de confusão gerada com o conjunto de teste. O modelo obteve acurácia de 85,92% e demonstrou um desempenho equilibrado entre as classes. Observa-se que os erros de classificação estão distribuídos entre 1.612 Falsos Positivos e 1.530 Falsos Negativos. O leve predomínio de Falsos Positivos indica que a rede é sensível a alterações severas na cobertura do solo, podendo classificar erroneamente outras degradações antrópicas ou naturais como atividade

mineradora.

Na análise qualitativa, nota-se que essas falhas ocorrem frequentemente em áreas de transição. A Figura 9 ilustra um caso de Falso Positivo, onde uma clareira de desmatamento recente foi classificada como garimpo. Nesses cenários, a falta de vegetação e o solo exposto criam uma assinatura visual muito parecida com a de uma cava de mineração, dificultando a distinção feita apenas com imagens RGB. Esses resultados sugerem que o uso de dados multitemporais ou de outras bandas espectrais poderia ajudar a reduzir tais ambiguidades.

5 Conclusão

Este trabalho atingiu seu objetivo ao desenvolver e validar um modelo de visão computacional baseado em Redes Neurais Convolucionais capaz de identificar frentes de garimpo na Amazônia com precisão. A análise inicial, por meio de Análise Exploratória de Dados e modelos de *baseline*, evidenciou que descritores estatísticos globais e algoritmos clássicos de aprendizado de máquina são insuficientes para lidar com a complexidade visual do problema, apresentando desempenho em torno de 72% de acurácia e AUC de 0,80. Esses resultados confirmaram que a ausência de contexto espacial leva a ambiguidades frequentes entre garimpo, nuvens, plumas de sedimentos e outras feições naturais.

A adoção de Redes Neurais Convolucionais profundas, em especial da arquitetura EfficientNet-B0 aliada à transferência de aprendizado e ao *fine-tuning*, representou o ponto de inflexão da pesquisa. Essa abordagem permitiu capturar hierarquias espaciais e semânticas específicas das cicatrizes de mineração, elevando a acurácia para 85,92% e a AUC para 0,9371. Os resultados demonstram que o Aprendizado Profundo é essencial para superar os ruídos e as ambiguidades inerentes ao monitoramento orbital na Amazônia, tornando a detecção automática de garimpo operacionalmente viável em larga escala [Tan and Le, 2019].

Além do desempenho alcançado, o trabalho contribui com um fluxo metodológico reproduzível de coleta e processamento de dados no Google Earth Engine, um *dataset* rotulado com mais de 111 mil imagens e um repositório de código aberto, fomentando a transparência e a continuidade da pesquisa.

Como trabalhos futuros, destacam-se a expansão do modelo para cenários multiclasse, a incorporação de séries temporais de imagens para análise da dinâmica do uso do solo, a adaptação das arquiteturas para execução em dispositivos de borda e a realização de avaliações estratificadas de desempenho focadas em cenários visuais ambíguos, como a presença de nuvens, rios com alta carga de sedimentos e áreas de solo exposto não minerado. Essas extensões têm potencial para ampliar a aplicabilidade prática da solução, reforçando o papel da Computação como ferramenta estratégica no apoio à fiscalização ambiental e à preservação da Amazônia.

Declarações complementares

Agradecimentos

Os autores agradecem ao Google Earth Engine pela disponibilização da infraestrutura computacional utilizada no processamento dos dados.

Contribuições dos autores

Conceptualização: LG, FA, TG e ER. Recursos: LG, FA e TG. Software: LG. Supervisão: ER. Validação: FA, TG e ER. Administração do Projeto: ER. Escrita do Manuscrito: LG e FA. Revisão e Edição do Manuscrito: LG, FA, TG e ER. LG é o principal responsável pela realização deste trabalho. Todos os autores leram e aprovaram o manuscrito final.

Conflitos de interesse

Os autores declaram que não têm nenhum conflito de interesses

Disponibilidade de dados e materiais

Os arquivos notebooks utilizados para processamento dos dados e re-realização dos experimentos estão disponíveis em https://github.com/leonardogrupioni/TCC_CNN_Garimpo_Amazonia. O *dataset* está disponível em <https://www.kaggle.com/datasets/leogrupioni/dataset-amazonia-garimpo-binario>

Outras informações relevantes

Não se aplica.

Referências

- Boaro, J. M. C., dos Santos, P. T. C., Serra, A., Rego, V. G., Martins, C. V., and Junior, G. B. (2021). Satellite image segmentation of gold exploration areas in the amazon rainforest using u-net. pages 1–8. DOI: 10.1109/IHTC53077.2021.9698927.
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1):5–32. DOI: 10.1023/A:1010933404324.
- Camalan, S., Cui, K., Pauca, V. P., Alqahtani, S., Silman, M., Chan, R., Plemmons, R. J., Dethier, E. N., Fernandez, L. E., and Lutz, D. A. (2022). Change detection of amazonian alluvial gold mining using deep learning and sentinel-2 imagery. *Remote Sensing*, 14(7):1746. DOI: 10.3390/rs14071746.
- Cutrim dos Santos, P. T. (2021). Aprimoramento da detecção de áreas de garimpo na região do tapajós através de redes adversárias de super-resolução. Monografia de Bacharelado. Disponível em: <https://monografias.ufma.br/jspui/handle/123456789/6366>.
- European Space Agency (2025). Sentinel-2 user handbook. Disponível em: <https://sentinels.copernicus.eu/web/sentinel>. Acesso em: 13/01/2026.
- Gallwey, J., Robiati, C., Coggan, J., Vogt, D., and Eyre, M. (2020). A sentinel-2 based multispectral convolutional neural network for detecting artisanal small-scale mining in ghana: Applying deep learning to shallow mining. *Remote Sensing of Environment*, 248:111970. DOI: 10.1016/j.rse.2020.111970.
- Global Initiative Against Transnational Organized Crime (2023). Amazon underworld: economias criminosas na maior floresta tropical do mundo. Technical report, GI-TOC and Amazon Watch and InfoAmazonia, Genebra, Suíça. Relatório institucional. Disponível em: <https://globalinitiative.net/wp-content/uploads/2023/11/Amazon%20Underworld-Economias-criminosas-na-maior%20floresta-tropical-do-mundo-GI-TOC%20Novembro-de-2023.pdf>.
- Goodfellow, I., Bengio, Y., and Courville, A. (2016). *Deep Learning*. MIT Press, Cambridge.

- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., and Moore, R. (2017). Google earth engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, 202:18–27. DOI: 10.1016/j.rse.2017.06.031.
- Instituto Nacional de Pesquisas Espaciais (2024). Sistema deter – detecção de desmatamento em tempo real. Disponível em: <http://www.obt.inpe.br/OBT/assuntos/programas/amazonia>. Acesso em: 13/01/2026.
- Lima, L. C. R. (2022). Mapeamento das áreas de garimpo em terras indígenas munduruku utilizando modelo baseado em conhecimento e integração multisensores. Trabalho de Conclusão de Curso. Disponível em: <https://repositorio.ifg.edu.br/handle/prefix/1450>.
- MapBiomas (2023). Amazônia concentra mais de 90% do garimpo no brasil. Disponível em: <https://brasil.mapbiomas.org/2023/09/22/amazonia-concentra-mais-de-90-do-2Dgarimpo-no-brasil/>. Acesso em: 13/01/2026.
- Molina, L. P. (2023). Terra rasgada: como avança o garimpo na amazônia brasileira. Technical report, Aliança em Defesa dos Territórios, Brasília, Brasil. Obra organizada. Disponível em: <https://acervo.socioambiental.org/sites/default/files/documents/o3d00050.pdf>.
- Qiu, S., Zhu, Z., and He, B. (2019). Fmask 4.0: Improved cloud and cloud shadow detection in landsats 4–8 and sentinel-2 imagery. *Remote Sensing of Environment*, 231:111205. DOI: 10.1016/j.rse.2019.05.024.
- RAISG (2025). Illegal mining shapefiles. Rede Amazônica de Informação Socioambiental Georreferenciada. Disponível em: <https://www.raisg.org/en/maps/> Acesso em: 13/01/2026.
- Rodrigues, L. P. S. (2024). *Inteligência Artificial para Analisar o Desmatamento na Região Amazônica Brasileira*. PhD thesis, Universidade do Porto. Disponível em: <https://www.proquest.com/openview/1d85364f9c39b4c5f8565d6023d81e87/>.
- Sentinel Hub (2024). s2cloudless: Machine learning cloud detector for sentinel-2 imagery. Disponível em: <https://docs.sentinel-hub.com>. Acesso em: 13/01/2026.
- Shorten, C. and Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of big data*, 6(1):1–48. DOI: 10.1186/s40537-019-0197-0.
- Sokolova, M. and Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information Processing & Management*, 45(4):427–437. DOI: 10.1016/j.ipm.2009.03.002.
- Tan, M. and Le, Q. (2019). EfficientNet: Rethinking model scaling for convolutional neural networks. In *Proceedings of the 36th International Conference on Machine Learning*, volume 97 of *Proceedings of Machine Learning Research*, pages 6105–6114. PMLR. DOI: 10.48550/arXiv.1905.11946.
- U.S. Geological Survey (2022). Fifty years of landsat: Observing earth to look forward. Disponível em: <https://www.usgs.gov/news/featured-story/fifty-years-landsat-observing-earth-look-2Dforward>. Acesso em: 13/01/2026.