

Quantificação da Perda Florestal em Assentamentos da Amazônia Legal por Meio de Sensoriamento Remoto com Inteligência Artificial

Quantifying Forest Loss in Legal Amazon Settlements through AI-Driven Remote Sensing

Sabrina do Carmo Alves¹; Laura Coelho de Andrade²; Arthur Amaral e Silva³; Helóisa Sâmela Borges⁴; Izabela Farias Oliveira⁵; Darlan Miranda Nunes⁶; Maria Lucia Calijuri⁷

¹ Universidade Federal de Viçosa, Departamento de Engenharia Civil, Viçosa/MG, Brasil. Email: sabrinacarmoalves@yahoo.com
ORCID: <https://orcid.org/0000-0001-8618-5840>

² Universidade Federal de Viçosa, Departamento de Engenharia Civil, Viçosa/MG, Brasil. Email: laura.andrade@ufv.br
ORCID: <https://orcid.org/0000-0003-3693-2208>

³ Universidade Federal de Viçosa, Departamento de Engenharia Civil, Viçosa/MG, Brasil. Email: arthuramaral.e.a@gmail.com
ORCID: <https://orcid.org/0000-0001-5548-459X>

⁴ Universidade Federal de Viçosa, Departamento de Engenharia Civil, Viçosa/MG, Brasil. Email: heloisa.borges@ufv.br
ORCID: <https://orcid.org/0009-0002-0220-3154>

⁵ Universidade Federal de Viçosa, Departamento de Engenharia Civil, Viçosa/MG, Brasil. Email: izabela.fo@gmail.com
ORCID: <https://orcid.org/0009-0009-7399-9592>

⁶ Universidade Federal de Viçosa, Departamento de Engenharia Civil, Viçosa/MG, Brasil. Email: darlan.nunes@ufv.br
ORCID: <https://orcid.org/0000-0001-5566-7919>

⁷ Universidade Federal de Viçosa, Departamento de Engenharia Civil, Viçosa/MG, Brasil. Email: calijuri@ufv.br
ORCID: <https://orcid.org/0000-0002-0918-2475>

Resumo: A floresta amazônica, um componente crucial do sistema climático da Terra, enfrenta um aumento do desmatamento, especialmente em áreas de assentamentos estabelecidas por meio de programas de reforma agrária. Este estudo investiga a perda florestal no Assentamento Alcobaça e no Trecho Juma, localizados na Amazônia Legal, no período de 2018 a 2022, utilizando técnicas de sensoriamento remoto e inteligência artificial (IA). Imagens do satélite Sentinel-2 foram analisadas por meio de algoritmos de aprendizado de máquina, incluindo Máquinas de Vetores de Suporte (SVM), Florestas Aleatórias (RF), Árvores de Decisão (DT) e Redes Neurais Convolucionais (CNNs), para classificar a cobertura da terra e quantificar as tendências de desmatamento. Os resultados demonstraram que as CNNs superaram os demais classificadores, atingindo a maior acurácia e melhor identificando os padrões de desmatamento ao longo do tempo. O modelo treinado foi então aplicado ao Trecho Juma para avaliar sua capacidade de generalização. Embora a abordagem com CNN tenha se mostrado eficaz, ela superestimou o desmatamento em 8,32% em 2022 em comparação com a classificação manual, evidenciando os desafios na transferência de modelos de aprendizado de máquina para diferentes regiões sem calibração adicional. Os resultados destacam também o potencial do sensoriamento remoto com IA para o monitoramento ambiental em larga escala, ao mesmo tempo em que reforçam a necessidade de treinamento e validação localizados para melhorar a precisão das classificações. Assim, esta pesquisa contribui para o desenvolvimento de métodos automatizados de avaliação da perda florestal, fornecendo informações valiosas para a gestão ambiental e a formulação de políticas públicas na Amazônia.

Palavras-chave: Sensoriamento Remoto; Aprendizado de Máquina; Desmatamento; Amazônia.

Abstract: The Amazon rainforest, a critical component of the Earth's climate system, faces increasing deforestation, particularly in settlement areas established through agrarian reform programs. This study investigates forest loss in the Alcobaça Settlement and Juma Tract in the Legal Amazon from 2018 to 2022 using remote sensing and artificial intelligence (AI) techniques. Sentinel-2 satellite imagery was analyzed using machine learning algorithms, including Support Vector Machine (SVM), Random Forest (RF), Decision Tree (DT), and Convolutional Neural Networks (CNNs), to classify land cover and quantify deforestation trends. The results demonstrate that CNN outperformed the other classifiers, achieving the highest accuracy and better identifying deforestation patterns over time. The trained model was then applied to the Juma Tract to assess its generalization capability. Although the CNN approach proved effective, it overestimated deforestation by 8.32% in 2022 compared to manual classification, highlighting challenges in transferring machine learning models to different regions without additional calibration. The findings emphasize the potential of AI-driven remote sensing for large-scale environmental monitoring while underscoring the necessity of localized training and validation to improve classification accuracy. This research contributes to the development of automated methods for forest loss assessment, providing valuable insights for environmental management and policy-making in the Amazon.

Keywords: Remote Sensing; Machine Learning; Deforestation; Amazon.

1. Introdução

A Amazônia, a maior floresta tropical do planeta, abrange cerca de 5,2 milhões de km² e desempenha um papel fundamental na regulação do clima, produção de oxigênio e preservação dos recursos hídricos e da biodiversidade (SALISBURY et al., 2012; FEARNSIDE, 2017; GATTI et al., 2021). Além de armazenar 25% do carbono terrestre, a região é vital para as comunidades locais, incluindo povos indígenas e populações tradicionais, que dependem da floresta para sua subsistência (NEPSTAD et al., 2008). No entanto, os conflitos fundiários envolvendo trabalhadores rurais, povos indígenas e o agronegócio — agravados por atividades ilegais como desmatamento e grilagem de terras — representam desafios significativos à conservação e à implementação de políticas públicas eficazes (BECKER, 2013; MIRANDA; PERES; CARVALHO, 2019). Dados recentes do INPE (2024) mostram que mais de 13% do desmatamento na Amazônia Legal ocorre dentro de assentamentos rurais, onde o monitoramento tradicional ainda é limitado, reforçando a necessidade de abordagens analíticas inovadoras.

Diante de sua estrutura e quadro de pessoal limitados, o INCRA tem firmado Termos de Execução Descentralizada (TEDs) com universidades, que têm sido fundamentais para ampliar sua capacidade técnica. Esses acordos permitem que as instituições acadêmicas apoiem esse órgão em pesquisas, levantamentos e análises, contribuindo para a regularização fundiária e o planejamento territorial na Amazônia Legal. Os TEDs fomentam a troca de conhecimento entre gestores e pesquisadores, promovendo a adoção de novas tecnologias e metodologias. Além disso, essas parcerias fortalecem a governança fundiária, aumentam a eficiência das políticas públicas e otimizam os recursos financeiros, com as universidades garantindo transparência e credibilidade (SILVA et al., 2022).

Em 2017, o INCRA firmou parceria com a Universidade Federal de Viçosa (UFV) por meio de um TED, resultando no Projeto RADIS, que, ao ser concluído no final de 2023, apoiou a revisão ocupacional para regularização fundiária de 308 assentamentos rurais, beneficiando mais de 30 mil famílias. Além disso, desde 2021, o INCRA e a UFV desenvolvem o Projeto AMARIS, voltado para o aprimoramento do cadastro de glebas públicas federais com fins de regularização fundiária, aplicando metodologias inovadoras para aprimorar o mapeamento das ocupações e garantir maior segurança jurídica na região.

As Glebas Federais representam áreas de domínio da União destinadas a diversos usos, enquanto os projetos de assentamento são unidades planejadas para redistribuição de terras e promoção da agricultura familiar, assegurando segurança jurídica e acesso às políticas públicas voltadas ao desenvolvimento rural sustentável (SANTOS; OLIVEIRA, 2021). A gestão dessas extensas áreas na Amazônia Legal continua sendo um desafio, dada sua complexidade socioambiental e as limitações do monitoramento in situ, o que torna as tecnologias de sensoriamento remoto indispensáveis.

Neste contexto, o sensoriamento remoto aliado a algoritmos de inteligência artificial (IA), como Machine Learning e Deep Learning, tornou-se uma ferramenta essencial para a gestão ambiental e territorial, permitindo a detecção em tempo quase real da perda florestal e o monitoramento do uso e cobertura da terra (COSTA; SOUZA; SILVA, 2020; RUDORFF et al., 2020). Embora estudos anteriores tenham mapeado o desmatamento em larga escala, poucos se concentraram nos assentamentos rurais e nas glebas federais, representando uma lacuna na pesquisa aplicada à governança territorial. Os modelos de IA são capazes de processar grandes volumes de dados, detectar mudanças sutis e antecipar tendências de degradação (PEREIRA et al., 2023), aumentando a precisão do monitoramento e a efetividade das políticas públicas (SOARES et al., 2021).

Assim, o presente estudo analisa e quantifica a perda florestal em um Projeto de Assentamento (PA) localizado no estado do Pará, dentro da Amazônia Legal, no período de 2018 a 2022, utilizando imagens de satélite e técnicas de IA. O modelo com melhor desempenho também foi aplicado a uma Gleba Federal sob gestão do INCRA, demonstrando a transferibilidade do método e seu potencial para apoiar a gestão territorial. O estudo busca responder às seguintes perguntas:

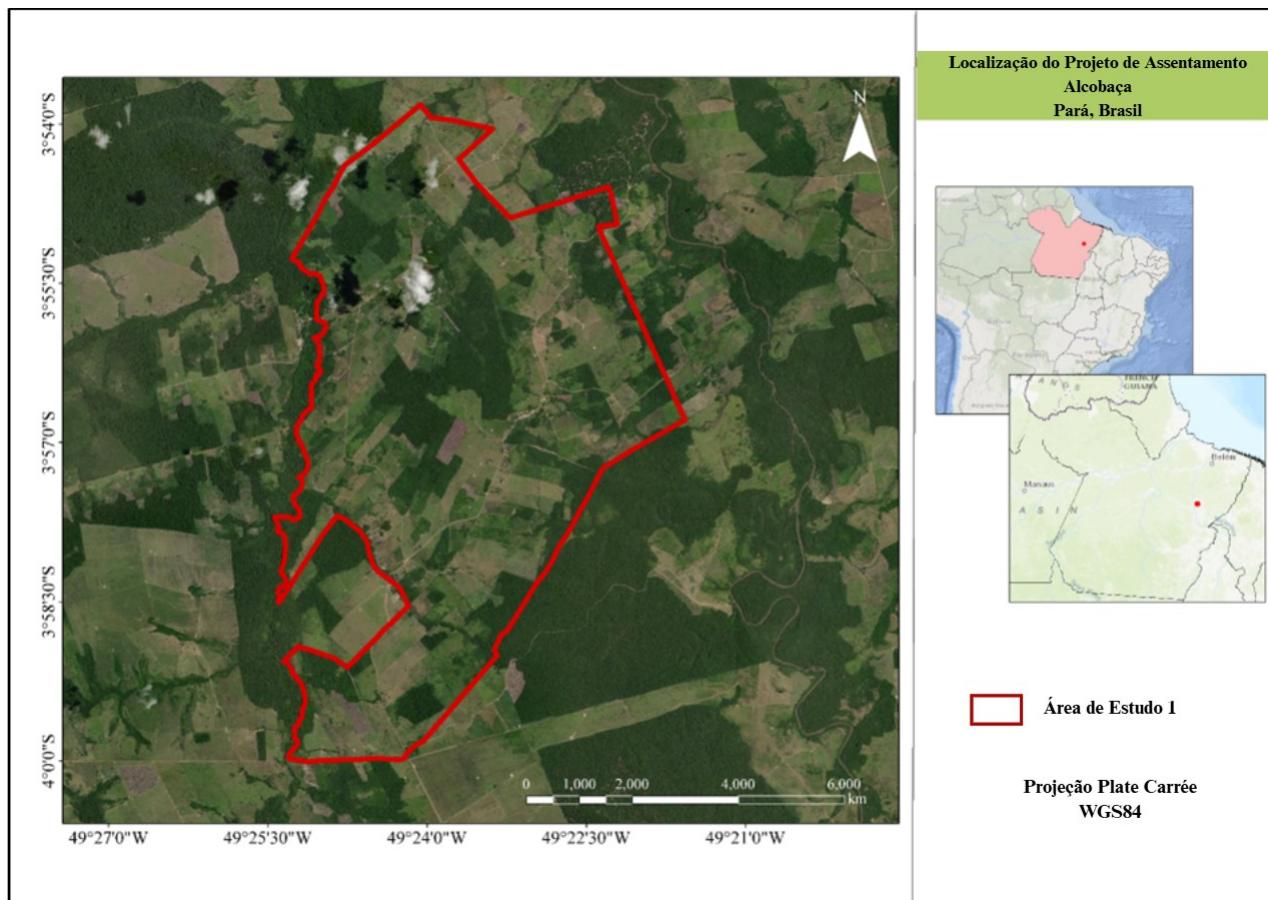
- (1) Qual é a acurácia do método proposto baseado em IA para detecção de perda florestal? E
- (2) Como ele se compara às técnicas tradicionais de sensoriamento remoto na identificação do desmatamento em Glebas Federais?

2. Materiais e Métodos

2.1 Área de Estudo

¹<https://dataspace.copernicus.eu/>

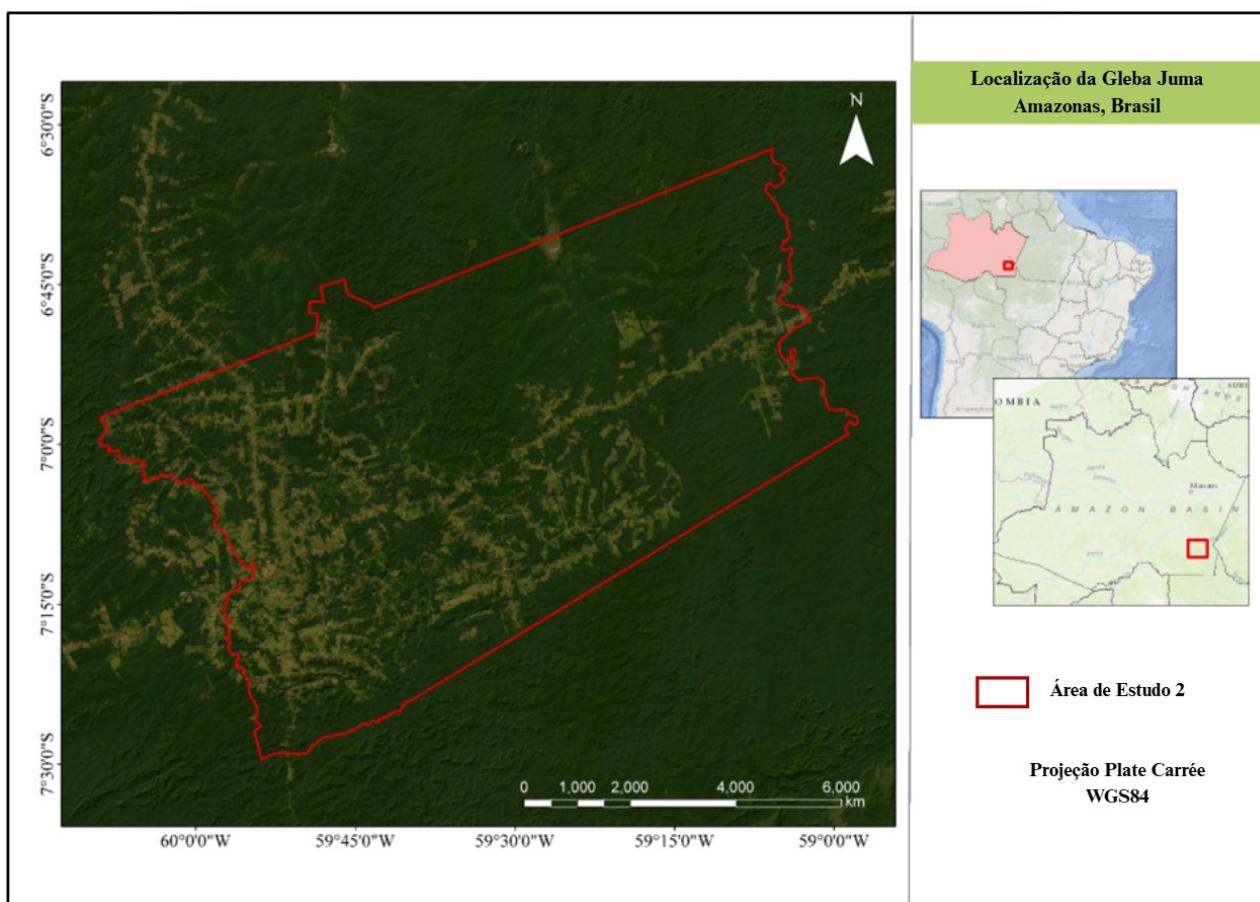
Para este estudo, as áreas selecionadas foram o Projeto de Assentamento (PA) Alcobaça, localizado no estado do Pará, no município de Breu Branco (Figura 1), e a região de Apuí, no estado do Amazonas, onde está situada a Gleba Federal Juma (Figura 2).



*Figura 1 – Localização do PA Alcobaça – Pará, Brasil.
Fonte: Autores (2025).*

O estado do Pará é a segunda maior unidade federativa do Brasil em extensão territorial, com uma área de 1.245.870,704 km², dos quais 1.745,77 km² são urbanizados (IBGE, 2022). O Projeto de Assentamento Alcobaça (PA) abrange uma área de aproximadamente 5.000 hectares.

¹<https://dataspace.copernicus.eu/>



*Figura 2 – Localização da Gleba Juma, Amazonas, Brasil.
Fonte: Autores (2025).*

A Gleba Juma, localizada no município de Apuí, no estado do Amazonas, foi originalmente criada como Projeto de Assentamento Dirigido (PAD) “Rio Juma” em 1982, abrangendo aproximadamente 689.000 hectares, no âmbito das políticas de colonização do INCRA para a Amazônia (GALUCH; DA COSTA, 2023). Inicialmente destinada à agricultura familiar, a área passou por um intenso processo de especulação fundiária, concentração de terras e expansão da pecuária, o que levou à perda de seu status de assentamento. Esse processo resultou na reclassificação do território como terra pública, consolidando sua integração ao mercado fundiário formal. A mudança favoreceu a expansão do agronegócio e contribuiu para o aumento das ocupações irregulares e do desmatamento na região (SANTOS; PONTES FILHO, 2024).

2.2 Métodos

A metodologia adotada neste estudo segue uma sequência estruturada em etapas, conforme ilustrado no fluxograma da Figura 3. As principais fases incluem a preparação da base de dados, o processamento, a obtenção dos resultados e a análise, conforme detalhado a seguir.

¹<https://dataspace.copernicus.eu/>

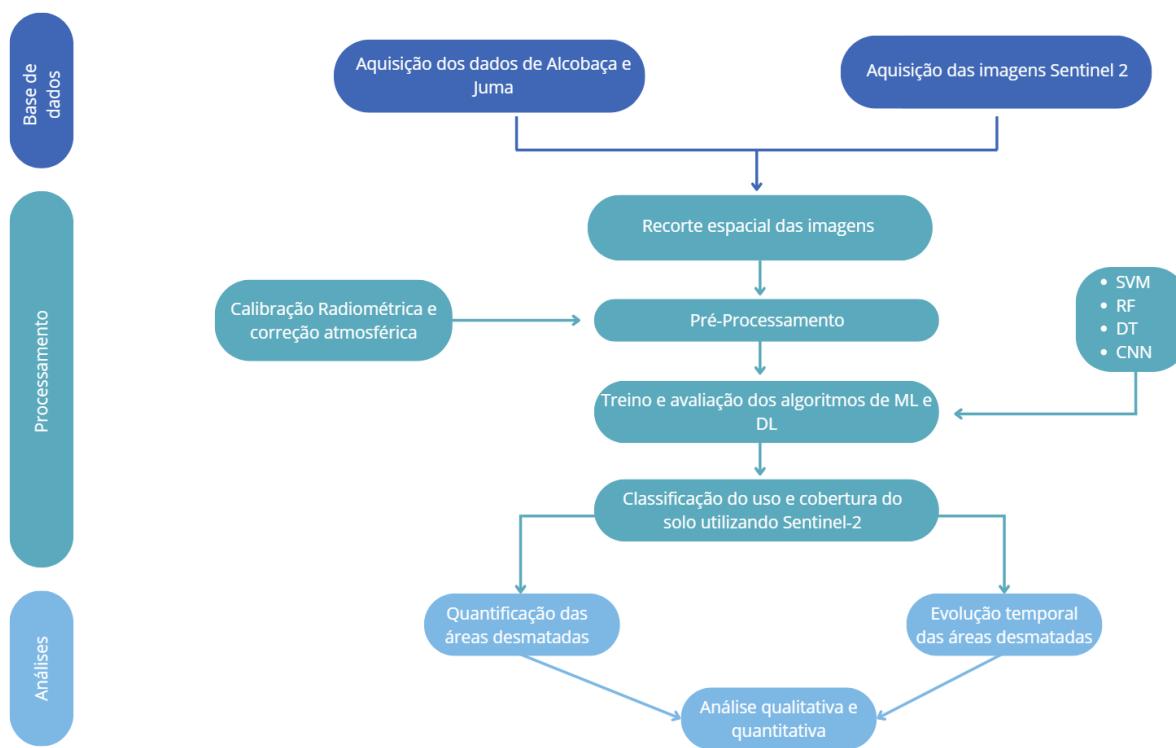


Figura 3 – Fluxograma Metodológico.

Fonte: Autores (2025).

2.2.1 Fonte de Dados

Inicialmente, foi definida a área de estudo, correspondente ao Projeto de Assentamento (PA) Alcobaça, no estado do Pará, incluído no escopo do Projeto RADIS-UFV, bem como a região da Gleba Juma, localizada no estado do Amazonas, que constitui a área de estudo do Projeto AMARIS.

É importante destacar que, para o PA Alcobaça, a área de estudo foi delimitada ao próprio assentamento. Em contraste, para a Gleba Juma, foi analisada toda a porção disponível na imagem orbital, com o objetivo de classificar um cenário “pior”, abrangendo uma área maior e maior diversidade de respostas espectrais.

Uma vez estabelecidas as áreas de interesse, foram obtidas imagens orbitais do satélite Sentinel-2 por meio do portal Copernicus¹, referentes aos anos de 2018, 2019, 2020, 2021 e 2022 para o PA Alcobaça, e aos anos de 2018 e 2022 para a Gleba Juma, visando quantificar a área desmatada nesta última ao longo de quatro anos.

Para este estudo, foram consideradas apenas as bandas espectrais com resolução espacial de 10 metros — azul, verde, vermelha e infravermelho próximo. Além disso, buscou-se selecionar imagens com a menor cobertura de nuvens possível para ambas as localidades.

2.2.2 Processamento

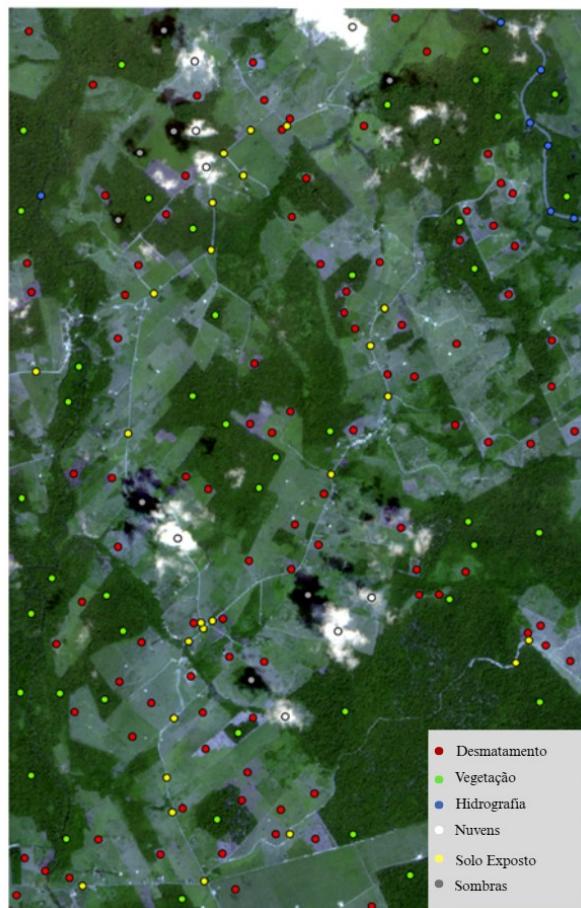
A etapa seguinte consistiu no pré-processamento das imagens Sentinel-2 selecionadas para ambas as localidades. Primeiramente, foi realizada a calibração radiométrica utilizando os metadados das imagens, ajustando os valores de radiância para corrigir os ganhos e desvios discrepantes das bandas.

Em seguida, aplicou-se a correção atmosférica por meio do método Dark Object Subtraction (DOS). Esse processo permitiu a remoção dos efeitos de espalhamento atmosférico, subtraindo o menor valor de pixel como assinatura de fundo da imagem.

Com as imagens pré-processadas, foi realizado o recorte espacial para o PA Alcobaça, utilizando um retângulo delimitador ao redor da área de estudo, resultando em cinco (05) imagens correspondentes a cada ano analisado.

¹<https://dataspace.copernicus.eu/>

Posteriormente, foram preparadas as amostras para o treinamento dos modelos de aprendizado de máquina, considerando as características específicas de cada cena. Foi definido um conjunto de pontos espacialmente distribuídos sobre a área de estudo, representando as seis classes de cobertura e uso da terra consideradas: Floresta, Desmatamento, Solo Exposto, Nuvens, Sombras e Hidrografia (Figura 4).



*Figura 4 – Distribuição dos pontos no PA Alcobaça.
Fonte: Autores (2025).*

2.2.3 Algoritmos de Inteligência Artificial

Entre os métodos de Inteligência Artificial (Machine Learning e Deep Learning), foram testados os algoritmos Support Vector Machine (SVM), Random Forest (RF), Decision Tree (DT) e Redes Neurais Convolucionais (RNC), uma vez que esses métodos são amplamente utilizados na classificação de imagens orbitais (PAL; MATHER, 2005; BELGIU; DRĂGUT¹, 2016; MAGGIORI et al., 2017; SHARMA; KUMAR, 2016; ZHU et al., 2017).

2.2.3.1 Support Vector Machine (SVM)

O algoritmo SVM (Support Vector Machine) é uma ferramenta amplamente aplicada em tarefas de regressão e classificação. Sua principal abordagem consiste em encontrar um hiperplano que funcione como superfície de decisão, separando as classes de dados em um espaço de alta dimensionalidade (GRAF et al., 2004; SOUSA, 2009). A principal característica do SVM é sua capacidade de minimizar a margem entre as classes e o hiperplano separador, garantindo robustez e alta capacidade de generalização nos resultados finais (BONESSO, 2013).

¹<https://dataspace.copernicus.eu/>

2.2.3.2. Random Forest (RF)

Uma das principais vantagens desse algoritmo é a diversidade introduzida pela aleatoriedade na seleção de subconjuntos de dados e atributos, o que torna o Random Forest resistente a outliers e ruídos nos dados, assegurando melhor capacidade de generalização. O método se destaca pela elevada precisão, especialmente em situações com escassez de dados ou alta dimensionalidade no espaço de atributos, demonstrando grande potencial de aplicação em sistemas reais complexos.

Neste estudo, foi empregada a função RandomForestClassifier, com votação majoritária das árvores para realizar a classificação dos dados.

2.2.3.3. Decision Tree (DT)

O método Decision Tree constrói modelos com base em regras simples derivadas dos dados, oferecendo facilidade de uso, suporte a diferentes tipos de dados e transparência nos resultados, sendo considerado um modelo “caixa branca” (AKAR; GÜNGÖR, 2012). No entanto, ele pode gerar árvores excessivamente complexas, resultando em overfitting e baixa generalização.

Técnicas como poda (pruning) e limitação de profundidade ajudam a mitigar esse problema. O modelo também pode ser instável e tendencioso em conjuntos de dados desbalanceados. A construção ideal da árvore normalmente depende de heurísticas, que nem sempre garantem soluções globalmente ótimas (LEE; CHEANG; MOSLEHPOUR, 2022; NOWOZIN et al., 2011).

2.2.3.4. Redes Neurais Convolucionais

As Redes Neurais Convolucionais (RNC) ou *Convolutional Neural Network* (CNN) são modelos de Deep Learning adequados para dados com estrutura em grade, como imagens de satélite. Sua arquitetura em camadas hierárquicas permite aprender padrões espaciais a partir dos dados de entrada, aprimorando o desempenho em tarefas de sensoriamento remoto (MAGGIORI et al., 2017; ZHU et al., 2017).

As camadas convolucionais extraem características como bordas e texturas, aprendidas por meio do backpropagation, enquanto as camadas de pooling reduzem as dimensões espaciais e o custo computacional (CIRESAN et al., 2011; MAGGIORI et al., 2017).

Diferentemente dos métodos tradicionais, que exigem a extração manual de atributos, as CNNs aprendem automaticamente os padrões relevantes. No entanto, sua aplicação depende de grandes volumes de dados rotulados, o que pode representar uma limitação em regiões remotas (ZHU et al., 2017).

2.2.4. Análises — Métricas para Avaliação do Desempenho dos Modelos

A avaliação dos modelos para o PA Alcobaça foi realizada utilizando os parâmetros de acurácia, precisão, revocação (recall), F1-score, índice Kappa, desvio padrão e RMSE (Root Mean Squared Error), permitindo uma avaliação abrangente da qualidade dos resultados. Além disso, foram quantificadas as áreas de ocorrência de perda de vegetação segundo cada algoritmo, e realizada uma análise temporal de sua evolução.

Para a Gleba Juma, onde foi aplicado o modelo de melhor desempenho para os anos de 2018 e 2022, a avaliação da metodologia foi conduzida por meio da comparação entre a área de perda florestal classificada manualmente por um especialista e a classificação automática para os anos mencionados, também considerando os parâmetros de acurácia, precisão, recall, F1-score e índice Kappa. Essa análise também pode ser avaliada qualitativamente.

3. Resultados

3.1 Projeto de Assentamento Alcobaça

As imagens Sentinel-2 correspondentes ao PA Alcobaça, referentes aos anos de 2018 a 2022, foram classificadas utilizando os algoritmos treinados com base nas amostras previamente definidas. O desempenho de cada algoritmo foi analisado por meio de métricas de avaliação aplicadas a cada um dos modelos gerados.

¹<https://dataspace.copernicus.eu/>

Em seguida, os modelos treinados foram aplicados para classificar as imagens. A partir das classes de cobertura e uso da terra resultantes, as áreas desmatadas no assentamento foram quantificadas ao longo dos anos.

A Tabela 1 apresenta os valores de acurácia obtidos para cada algoritmo, considerando as imagens dos cinco anos analisados.

Tabela 1 – Acurácia depois do treinamento de cada algoritmo.

Algoritmo	2018	2019	2020	2021	2022
	Acurácia do algoritmo treinado (%)				
SVM	92.31	92.31	95.06	93.75	95.18
RF	96.61	90.91	96.69	97.92	96.77
DT	93.22	93.51	96.69	92.71	95.16
CNN	94.87	98.08	96.30	95.31	95.18

Fonte: Autores (2025).

Os valores apresentados na Tabela 1 acima foram extraídos dos relatórios de avaliação dos modelos após as etapas de treinamento e teste.

Para avaliar o desempenho dos diferentes algoritmos aplicados à classificação das imagens de satélite, a Tabela 2 apresenta os valores médios de acurácia, desvio médio, raiz do erro quadrático médio (RMSE) e índice Kappa médio.

Tabela 2 – Avaliação da Performance dos Algoritmos.

Estatísticas Gerais	Algoritmos			
	SVM	RF	DT	CNN
Acurácia Média (%)	93.72	95.78	94.26	95.95
Desvio Médio	1.13	1.95	1.33	0.99
Root Mean Squared Error	2.83	17.18	8.01	3.62
Índice Kappa Médio	0.89	0.90	0.88	0.92

Fonte: Autores (2025).

Os valores médios do índice Kappa para os algoritmos testados variaram entre 0,88 e 0,92, sendo que a CNN obteve o maior valor (0,92), seguida pelo Random Forest (0,90), SVM (0,89) e Decision Tree (0,88). A CNN também apresentou o menor desvio médio (0,99), enquanto o Random Forest registrou o maior desvio médio (1,95), indicando maior variabilidade no desempenho do modelo ao longo dos anos analisados.

Assim, o uso de redes neurais convolucionais (CNNs) destacou-se pela capacidade de detectar pequenos fragmentos de desmatamento que não foram identificados por outros algoritmos. Essa habilidade decorre da estrutura das CNNs, que permite capturar características sutis nas imagens. As CNNs apresentaram a maior acurácia média e o menor desvio médio, alcançando, em 2019, uma acurácia de 98,08%, a melhor entre todos os algoritmos.

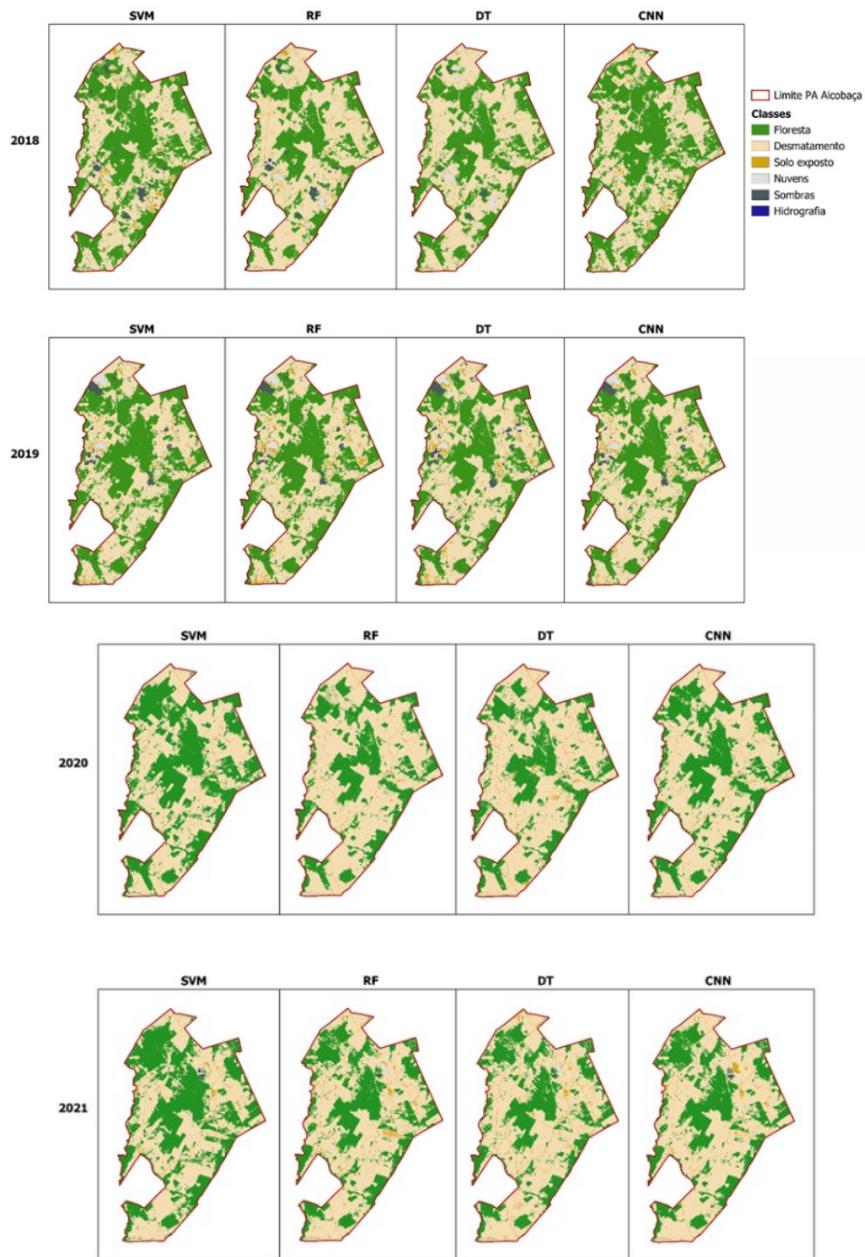
O algoritmo SVM também apresentou bom desempenho em termos de desvio médio, exibindo um RMSE mais baixo, porém com acurácia média ligeiramente inferior em comparação aos demais modelos. Por outro lado, o Random Forest demonstrou eficácia na generalização dos padrões de classificação ao longo dos anos analisados, mas apresentou o maior desvio médio registrado. Foram observadas inconsistências, especialmente em 2019, possivelmente atribuídas à sensibilidade do algoritmo a variáveis específicas, como variações climáticas e heterogeneidade dos dados de entrada.

Entretanto, a escolha do algoritmo deve ser feita com cautela, considerando diversos fatores, como a resolução espacial das imagens, a representatividade das amostras utilizadas, as condições ambientais vigentes durante a aquisição das imagens e a disponibilidade de dados de treinamento de alta qualidade. Cada um desses fatores pode influenciar

¹<https://dataspace.copernicus.eu/>

significativamente o desempenho dos modelos, tornando a seleção do algoritmo um processo que deve ser adaptado ao contexto específico da aplicação (CIHLAR, 2000; FOODY, 2002; YU et al., 2014).

Em relação à cobertura e uso da terra na área do PA Alcobaça durante o período analisado (2018 a 2022), observou-se uma tendência de redução da cobertura florestal, indicando um aumento do desmatamento na área do assentamento (Figura 5).



¹<https://dataspace.copernicus.eu/>

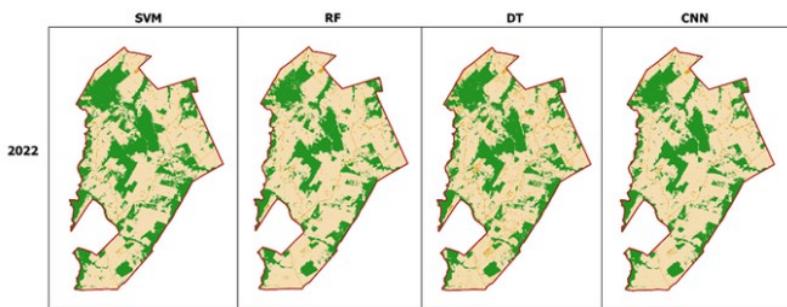


Figura 5 – Cobertura e Uso da Terra no PA Alcobaça, resultantes da classificação das imagens ao longo dos anos por cada algoritmo.

Fonte: Autores (2025).

Durante o período de cinco anos analisado neste estudo, foi realizada uma avaliação comparativa das áreas classificadas como floresta pelos diferentes algoritmos testados. A Tabela 3 apresenta a extensão dessas áreas em hectares, evidenciando a redução da cobertura florestal dentro dos limites do Projeto de Assentamento (PA).

Esses dados indicam a magnitude do desmatamento e a eficiência relativa de cada algoritmo na detecção das mudanças na cobertura vegetal ao longo do tempo, contribuindo para uma melhor compreensão dos impactos ambientais em áreas de assentamento.

Tabela 3 – Perda de cobertura florestal em Alcobaça - SP ao longo de um período de 5 anos.

Algoritmo	2018	2022	Diferença Total nas Áreas de Floresta no PA Alcobaça ao Longo de 5 Anos (ha)
	Área (ha)		
SVM	2210.93	1652.32	558.6
RF	1676.98	1337.410	339.6
DT	1644.97	1424.56	220.4
CNN	1848.50	1351.42	497.1

Fonte: Autores (2025).

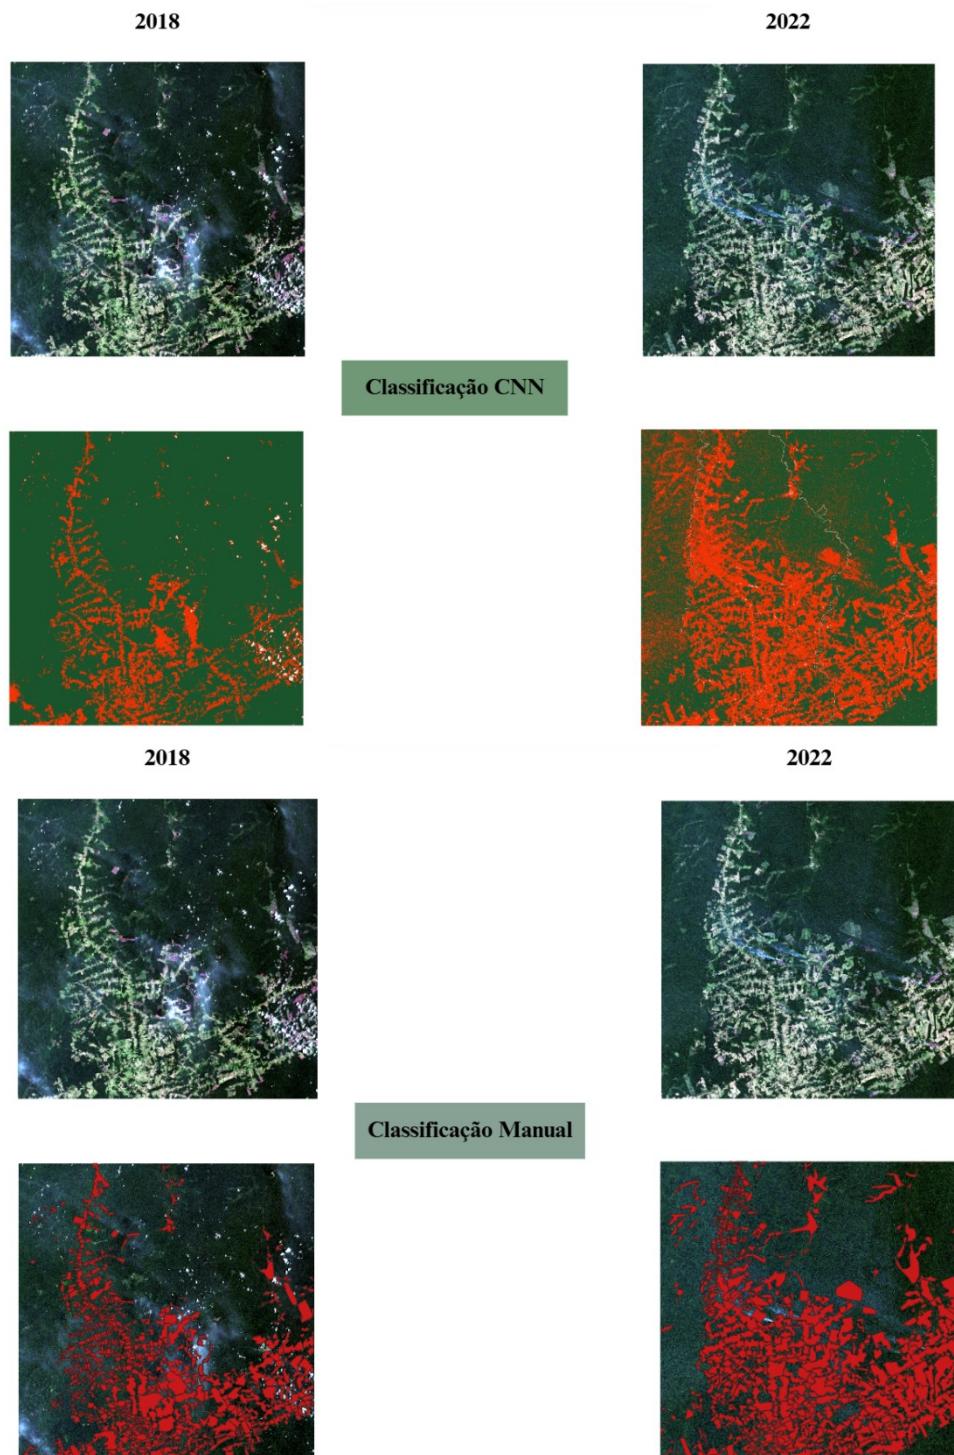
3.2 Gleba Juma

Com base nos resultados obtidos para o PA Alcobaça, onde a CNN apresentou o melhor desempenho e maior concordância, esse algoritmo foi selecionado para a classificação automática da Gleba Juma, na região amazônica, utilizando o modelo calibrado para o ano de 2018.

A decisão de aplicar o modelo de CNN treinado no PA Alcobaça diretamente à região da Gleba Juma baseou-se na semelhança da cobertura vegetal e dos padrões de ocupação do solo entre as duas áreas. No entanto, é importante ressaltar que, apesar de compartilharem características ecológicas, diferenças nas dinâmicas de uso do solo e nas condições ambientais podem afetar a acurácia do modelo quando transferido para uma nova localidade. Além disso, como não foram utilizados novos dados de treinamento para a Gleba Juma, a generalização do modelo pode resultar em variações nos resultados.

A Figura 6 ilustra a classificação realizada pela rede neural convolucional (CNN) e a classificação manual para a imagem contendo a Gleba Juma.

¹<https://dataspace.copernicus.eu/>



*Figura 6 – Classificação por CNN e Classificação Manual para a Região da Gleba Juma.
Fonte: Autores (2025).*

A análise quantitativa revelou que, entre 2018 e 2022, a CNN estimou uma perda de cobertura florestal de aproximadamente 50.492,97 hectares. Essa discrepância sugere que a CNN superestimou o desmatamento em 2022,

¹<https://dataspace.copernicus.eu/>

identificando cerca de 8,32% a mais de área perdida em comparação à classificação manual. Em contrapartida, para o ano de 2018, a CNN subestimou a perda florestal em 5,23%, indicando que o modelo pode ter apresentado viés ao longo do tempo.

A Tabela 4 destaca a porcentagem de valores equivalentes calculados com base na classificação por CNN e na classificação manual.

Tabela 4 – Áreas de Perda Florestal de Acordo com a Classificação por CNN e Classificação Manual.

	CNN (ha)	Manual (ha)	Diferença Absoluta (ha)	Diferença (%)
2018	273,086.03	288,150.07	15,064.04	5.23
2022	461,413.68	425,984.75	35,428.93	8.32
Perda de Cobertura Florestal (5 anos)	188,327.65	137,834.68	50,492.97	36.63

Fonte: Autores (2025).

Os resultados das métricas médias calculadas para a Gleba Juma são apresentados na Tabela 5, destacando o desempenho da classificação com base nos parâmetros de acurácia, índice Kappa, recall, precisão e F1-score.

Tabela 5 – Métricas da Classificação da Gleba Juma.

Métricas Médias	CNN
Acurácia (%)	82.29
Precisão (%)	72.69
Recall (%)	79.57
F1-Score (%)	75.97
Kappa	0.62

Fonte: Autores (2025).

Os resultados da classificação indicam um desempenho satisfatório, com acurácia média de 82,29% e índice Kappa de 0,62, sugerindo uma concordância moderada a substancial entre a classificação automática e a referência manual. A precisão média de 72,69% e o recall de 79,57% demonstram que o modelo conseguiu identificar a maioria das áreas de interesse, embora ainda haja uma taxa considerável de falsos positivos. O F1-Score de 75,97%, que equilibra precisão e recall, reforça que a classificação automática apresenta desempenho consistente, ainda que não esteja isenta de erros.

Além disso, é importante mencionar que a imagem completa cobre uma área de 1.197.538,08 hectares (11.975,38 km²), evidenciando que as diferenças entre as classificações manual e automática (CNN) são relativamente pequenas quando comparadas à área total analisada.

Para a validação da classificação manual, foi aplicada uma topologia com a regra de não sobreposição de polígonos, a fim de corrigir possíveis erros humanos durante a execução. Ademais, destaca-se que o processo de vetorização demandou aproximadamente 80 horas para ser concluído em ambas as imagens (2018 e 2022).

4. Discussões

4.1 Projeto de Assentamento Alcobaça

¹<https://dataspace.copernicus.eu/>

A análise dos modelos de classificação supervisionada para o PA Alcobaça revelou alto nível de acurácia e concordância com a classificação de referência. Autores como Fleiss, Levin e Paik (2003) classificam valores de Kappa acima de 0,75 como excelentes, enquanto Landis e Koch (1977) consideram que valores acima de 0,81 indicam concordância quase perfeita, o que está em conformidade com os resultados obtidos neste estudo.

Entre os modelos testados, a CNN apresentou o melhor desempenho geral, alcançando a maior acurácia e o menor desvio médio. Esse desempenho superior é atribuído à capacidade da CNN de capturar padrões espaciais e espectrais complexos nas imagens, evidenciada por seu índice Kappa mais elevado e pela detecção de pequenos fragmentos de desmatamento (Tabela 2). As redes neurais convolucionais vêm se destacando na classificação de uso e cobertura da terra devido à sua habilidade em extraír padrões complexos, reduzindo erros comumente observados em métodos tradicionais, como Random Forest (RF) e Support Vector Machine (SVM) (MAGGIORI et al., 2016). Entretanto, apesar de sua alta precisão, as CNNs apresentam desafios como alto custo computacional e a necessidade de grandes volumes de dados rotulados, o que pode limitar sua aplicação em casos com poucas amostras de treinamento. Nesse contexto, autores como Maggiori et al. (2016) e Zhu et al. (2017) destacam que estratégias de aprendizado semissupervisionado e aumento de dados (data augmentation) são soluções eficazes para mitigar essas limitações, permitindo melhor generalização dos modelos.

O modelo SVM apresentou desempenho intermediário, alcançando acurácia média de 93,72% e o menor erro quadrático médio ($RMSE = 2,83$) entre os modelos testados. Seu desempenho ligeiramente inferior pode estar relacionado à dificuldade em definir o hiperplano ótimo para separação das classes em áreas com padrões espectrais complexos, conforme apontado por Pal e Mather (2005).

Por fim, o modelo Decision Tree (DT) obteve o menor índice Kappa médio (0,88) e maior tendência ao overfitting, uma vez que tende a gerar árvores profundas e altamente especializadas com base nas amostras de treinamento. Esse comportamento reduz a capacidade de generalização do modelo para novos dados, resultando em desempenho inferior (NOWOZIN et al., 2011). Por outro lado, Sharma e Kumar (2016) argumentam que o uso de técnicas de seleção de atributos e poda (pruning) pode reduzir o overfitting, mantendo maior interpretabilidade em comparação a outros métodos baseados em árvores, dependendo do conjunto de dados utilizado.

Além da análise estatística dos modelos, a variação anual da cobertura florestal no PA Alcobaça demonstrou um aumento progressivo do desmatamento entre 2018 e 2022 (Tabela 5). Esses resultados reforçam a importância do monitoramento contínuo na região e a aplicação de abordagens baseadas em IA para fornecer informações rápidas e precisas sobre as mudanças na cobertura vegetal.

4.2 Gleba Juma

Para a Gleba Juma, foi aplicada uma abordagem distinta, na qual o modelo de CNN treinado no PA Alcobaça foi utilizado sem a introdução de novas amostras de treinamento, caracterizando uma classificação não supervisionada. Essa estratégia foi adotada para avaliar a capacidade de generalização do modelo em uma área com características semelhantes do bioma amazônico, porém sem ajustes específicos para suas condições ambientais e padrões de uso do solo.

Os resultados indicaram que o modelo superestimou o desmatamento em 2022 quando comparado à classificação manual, com uma diferença de aproximadamente 35.000 hectares (8,32%). Essa discrepância pode ser explicada pelo fato de o modelo ter sido treinado com dados de 2018 do PA Alcobaça, cujas características espectrais das classes diferem levemente das da Gleba Juma em 2022. Outro fator determinante foi a confusão entre solo exposto e áreas desmatadas, uma vez que a CNN classificou incorretamente áreas abertas como desmatadas devido às semelhanças espectrais.

Os resultados das métricas de classificação indicam um desempenho satisfatório, com acurácia de 82,29% e índice Kappa de 0,62, sugerindo concordância moderada a substancial entre a classificação automática e a referência manual (CONGALTON; GREEN, 2019). No entanto, a relação entre precisão (72,69%) e recall (79,57%) revela um desequilíbrio entre erros de comissão e omissão, também observável nos cálculos de área. A menor precisão em relação ao recall indica que o modelo é mais propenso a erros de comissão, classificando incorretamente áreas como desmatadas quando não são, o que contribui para a superestimação do desmatamento (FOODY, 2002). Por outro lado, o valor de recall mostra que também há erros de omissão, em que determinadas áreas pertencentes a uma classe não foram corretamente identificadas, levando à subestimação de certos fenômenos (OLOFSSON et al., 2014). O F1-Score de 75,97% confirma que a classificação mantém um desempenho equilibrado, embora ainda apresente tendência de inclusão indevida de pixels na classe alvo.

Outro ponto relevante é que a resolução espacial das imagens (10 m/pixel) ampliou os impactos dos erros de classificação. Cada erro representa 100 m² de área mal classificada, e pequenas falhas podem resultar em diferenças

¹<https://dataspace.copernicus.eu/>

significativas nas estimativas de desmatamento total — um problema já relatado em estudos sobre a influência da resolução espacial em modelos baseados em IA (CIHLAR, 2000; YU et al., 2014).

Adicionalmente, a classificação manual exigiu aproximadamente 80 horas de vetorização, reforçando a vantagem do uso da IA na automação de processos de monitoramento ambiental. No entanto, os resultados indicam que a aplicação de um modelo treinado em outra área requer ajustes e calibrações específicas para melhorar a acurácia. Entre as possíveis melhorias, destacam-se:

- Recalibração do modelo com amostras locais;
- Aplicação de técnicas de transferência de aprendizado (transfer learning) para ajuste fino dos pesos da rede;
- Ajustes na arquitetura da rede neural;
- Alinhamento temporal entre os dados de treinamento e as imagens classificadas (ZHU et al., 2017; SILVEIRA et al., 2020).

Esses refinamentos podem reduzir discrepâncias espectrais e espaciais, diminuindo os erros de classificação. Por fim, a análise da Gleba Juma ressalta a importância de testar a adaptabilidade dos modelos antes de sua aplicação em novas áreas, reforçando que a acurácia de um modelo supervisionado pode diminuir significativamente quando aplicado sem ajustes em contextos distintos.

5. Conclusões

A análise da perda de cobertura florestal no PA Alcobaça, por meio de classificação supervisionada, demonstrou a eficácia da aplicação da Inteligência Artificial ao sensoriamento remoto para a quantificação do desmatamento. A comparação entre diferentes algoritmos revelou que a CNN obteve o melhor desempenho, capturando padrões espaciais complexos e garantindo alta precisão na detecção de áreas desmatadas.

Com base nesses resultados, o modelo treinado em 2018 no PA Alcobaça foi aplicado à Gleba Juma para avaliar a viabilidade da transferência do aprendizado para outra área recentemente ocupada na Amazônia. Contudo, os resultados mostraram que, apesar de uma boa correspondência inicial, houve superestimação da perda florestal em 2022, destacando a necessidade de ajustes específicos para a nova região.

A Gleba Juma é uma das principais áreas de expansão da fronteira agrícola amazônica, com altas taxas de especulação fundiária, desmatamento e conversão de florestas em pastagens. A transição de Projeto de Assentamento para Terra Pública intensificou essas dinâmicas, consolidando sua integração ao mercado fundiário formal e ampliando os desafios para a governança ambiental e fundiária. Nesse contexto, a adoção de técnicas avançadas de monitoramento, como a classificação não supervisionada baseada em IA, torna-se uma estratégia essencial para a detecção rápida e precisa das mudanças de uso da terra, possibilitando ações mais eficazes de fiscalização e conservação.

Assim, este estudo reforça a importância do monitoramento contínuo do desmatamento na Amazônia, tanto para subsidiar políticas de conservação quanto para coibir práticas ilegais de conversão florestal. O uso estratégico da IA aplicada ao sensoriamento remoto pode revolucionar o monitoramento do bioma, fornecendo respostas rápidas, precisas e escaláveis para a gestão territorial no contexto de projetos de assentamento e terras públicas.

Entretanto, sua implementação deve ser conduzida de forma responsável, garantindo que as análises refletem com precisão a realidade de campo, evitando distorções que possam comprometer decisões ambientais e fundiárias na região. Pesquisas futuras devem considerar o uso de transfer learning ou fine-tuning para adaptar os modelos a novas regiões, o emprego de sistemas orbitais com melhor resolução espacial, além de análises de sensibilidade para compreender melhor a influência das variáveis ambientais nos resultados da classificação.

Referências

- AKAR, Ö.; GÜNGÖR, O. Classification of multispectral images using Random Forest algorithm. *Journal of Geodesy and Geoinformation*, v. 1, n. 2, p. 105–112, 2012.
- AKAR, Ö.; GÜNGÖR, O. Classification of multispectral images using Random Forest algorithm. *Journal of Geodesy and Geoinformation*, v. 1, n. 2, p. 105–112, 2012.
- BECKER, B. (2013). Amazônia: economia, ecologia e desafios do desenvolvimento sustentável. São Paulo: Editora XYZ.
- BECKER, B. K. (2013). Revisão das políticas de ocupação da Amazônia: é possível identificar modelos para projetar cenários? *Estudos Avançados*, 19(53), 71-86. Disponível em:

¹<https://dataspace.copernicus.eu/>

- https://docs.ufpr.br/~adilar/GEOPOL%C3%8DTICA2019/Geopolitica%20da%20Amazonia/Amaz%C3%B4nia_Pol%C3%A9tica%20de%20ocupa%C3%A7%C3%A3o.pdf
- BELGIU, M.; DRĂGUT, L. Random forest in remote sensing: A review of applications and future directions. *ISPRS journal of photogrammetry and remote sensing*, v. 114, p. 24-31, 2016.
- BEZERRA, J. F., FERREIRA, M. C., & OLIVEIRA, R. S. (2021). Desafios da regularização fundiária na Amazônia Legal: aspectos jurídicos e institucionais. *Revista Brasileira de Estudos Rurais e Urbanos*, 6(1), 85-102. Disponível em: <https://www.rberu.org.br/desafios-fundiarios-amazonia>
- BÖHM, S. M.; SOBIERANSKI, A. C. Análise de Performance de um Algoritmo de Reconhecimento Facial por Visão Computacional Aplicado a Sistemas Embarcados, 2021.
- BONESSO, D. Estimação dos Parâmetros do Kernel em um Classificador SVM na Classificação de Imagens Hiperespectrais em uma Abordagem Multiclasse, 2013.
- Brazil. (2018). Decree No. 9,311, of March 15, 2018. Regulates provisions of Law No. 8,629/1993 related to agrarian reform. Official Gazette of the Union. Retrieved from http://www.planalto.gov.br/ccivil_03/_ato2015-2018/2018/decreto/d9311.htm
- BREIMAN, L. Random Forests. Random Forests, 2001. Disponível em: <https://link.springer.com/article/10.1023/a:1010933404324>. Acesso em: 25 ago. 2024.
- CARVALHO, W. D. S., FILHO, F. J. C. M., & SANTOS, T. L. D. (2021). Uso e cobertura do solo utilizando a plataforma google earth engine (gee): estudo de caso em uma unidade de conservação / land use and land cover using the google earth engine platform (gee): case study in a conservation unit. *Brazilian Journal of Development*, 7(2), 15280-15300.
- CIHLAR, J. Land cover mapping of large areas from satellites: status and research priorities. *International journal of remote sensing*, v. 21, n. 6-7, p. 1093-1114, 2000.
- CIRESAN, D. C. et al. Flexible, High Performance Convolutional Neural Networks for Image Classification, 2011.
- CONGALTON, R. G., & GREEN, K. (2019). Assessing the accuracy of remotely sensed data: principles and practices. CRC press.
- COSTA, L. R., SOUZA, A. F., & SILVA, T. P. (2020). Aplicações de sensoriamento remoto para a gestão territorial na Amazônia: Desafios e perspectivas. *Revista Brasileira de Geografia*, 39(4), 281-299.
- FEARNSIDE, P. M. (2017). Desmatamento na Amazônia: impactos e soluções. Brasília: Editora Universidade.
- FERREIRA, A. M. M., & SALATI, E. (2005). Forças de transformação do ecossistema amazônico. *Estudos Avançados*, 19(53), 25-40. Disponível em: <https://www.scielo.br/j/ea/a/Y77GvYY7DkMnkRZynzQY5Qx/>
- FLEISS, J.L; LEVIN, B. AND PAIK, M.C. Statistical Methods for Rates and Proportions. Wiley Series in Probability and Statistics. John Wiley & Sons, Inc., Hoboken, NJ, USA, sep 2003.
- FRANKLIN, S. E., & WULDER, M. A. (2002). Remote sensing methods in medium spatial resolution satellite data land cover classification of large areas. *Progress in Physical Geography*, 26(2), 173-205.
- GADELHA, R. M. A. F. (2002). Conquista e ocupação da Amazônia: a fronteira Norte do Brasil. *Estudos Avançados*, 16(45), 31-50. Disponível em: <https://www.scielo.br/j/ea/a/8Y9Y8Y9Y8Y9Y8Y9Y8Y9Y8Y9Y8Y9Y/>
- GALUCH, M. V.; DA COSTA, A. M. Trajetórias e (des) ocupação: migrações, conflitos e expansão da fronteira agropecuária no sul do amazonas. *Amazônica-Revista de Antropologia*, v. 15, n. 1, p. 72-95, 2023.
- GATTI, L. V., ET AL. (2021). O papel da Amazônia na regulação climática global. *Journal of Climate Science*, 12(4), 350-364.
- GRAF, H. P. et al. Parallel Support Vector Machines: The Cascade SVM, 2004.

¹<https://dataspace.copernicus.eu/>

HOSSAIN, M. I. Support Vector Machine, 2022.

INTRODUÇÃO ÀS REDES NEURAIS CONVOLUCIONAIS. In: DEEP LEARNING BOOK. 2022. Disponível em: <https://www.deeplearningbook.com.br/introducao-as-redes-neurais-convolucionais>. Acesso em: 25 ago. 2024.

LEE, C. S.; CHEANG, P. Y. S.; MOSLEHPOUR, M. Predictive Analytics in Business Analytics: Decision Tree. Advances in Decision Sciences, , v. 26, n. 1, p. 1–30, 2022.

LOPES, M. V. R. Tratamento de Imprecisão na Geração de Árvores de Decisão, 2016.

MAGGIORI, E., TARABALKA, Y., CHARPIAT, G., & ALLIEZ, P. (2017). Convolutional Neural Networks for large-scale remote-sensing image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 55(2), 645–657. <https://doi.org/10.1109/TGRS.2016.2612821>

MEDEIROS, I. N.; TSEN, J. M.; FAVAN, J. R. Deep Learning Para Identificação e Classificação em Imagens de Manguezais, 2021.

MIRANDA, C., PERES, C. A., & CARVALHO, L. (2019). Governança fundiária e sustentabilidade na Amazônia: dilemas e perspectivas. *Estudos Avançados*, 33(96), 175-195. Disponível em: <https://www.scielo.br/j/ea/a/fundiaria-amazonia>

MIRANDA, E., ET AL. (2019). Conflitos fundiários e desenvolvimento na Amazônia Legal. *Estudos Sociais*, 22(2), 202-221.

NEPSTAD, D., ET AL. (2008). Amazônia: proteção e desenvolvimento sustentável. Rio de Janeiro: Editora UFRJ.

NOWOZIN, S. et al. Decision tree fields. Barcelona, Spain. International Conference on Computer Vision, 2011. Disponível em: <http://ieeexplore.ieee.org/document/6126429/>. Acesso em: 28 ago. 2024.

NOWOZIN, S., VEZHNEVETS, A. S., & LAMPERT, C. H. (2011). On parameter learning in CRF-based approaches to object class image segmentation. Proceedings of the 2011 International Conference on Machine Learning (ICML), Bellevue, WA.

OLOFSSON, P., FOODY, G. M., HEROLD, M., STEHMAN, S. V., WOODCOCK, C. E., & WULDER, M. A. (2014). Good practices for estimating area and assessing accuracy of land change. *Remote sensing of Environment*, 148, 42-57.

PAL, M., & MATHER, P. M. (2005). Support vector machines for classification in remote sensing. *International Journal of Remote Sensing*, 26(5), 1007–1011. <https://doi.org/10.1080/01431160512331314083>

PEIXOTO, F. (2009). Linha do tempo: Entenda como ocorreu a ocupação da Amazônia. *Imazon*. Disponível em: <https://imazon.org.br/imprensa/linha-do-tempo-entenda-como-ocorreu-a-ocupacao-da-amazonia/>

QUINLAN, J. R. Induction of decision trees. *Machine Learning*, v. 1, n. 1, p. 81–106, 1986.

RIGATTI, S. J. Random Forest, p. 9, 2016.

Salisbury, J., et al. (2012). Ecologia da Amazônia: uma visão geral. São Paulo: Editora ABC.

SANTOS, A. L., & OLIVEIRA, M. R. (2021). Regularização fundiária e reforma agrária no Brasil: desafios e perspectivas. *Revista de Direito Agrário e Desenvolvimento Rural*, 15(1), 45-67.

SENS, D. F. Rede Neural Convolucional para classificação de imagens SAR de desflorestamento na Amazônia, 2021.

SHARMA, H.; KUMAR, S. A Survey on Decision Tree Algorithms of Classification in Data Mining. *International Journal of Science and Research (IJSR)*, v. 5, n. 4, 2016.

SILVA, J. C. D. Rede Neural Convolucional Para o Diagnóstico de Rolamentos em Baixa Rotação, 2024.

¹<https://dataspace.copernicus.eu/>