

Análise Multitemporal do Desmatamento por CNNs na Região Tocantina a partir de Imagens Sentinel-2

Vilson Conceição Castro¹, Martony Demes da Silva¹

¹Superintendência de Tecnologias na Educação (STED)
Universidade Federal do Maranhão (UFMA)

Abstract. *Deforestation in the Tocantina Region demands new approaches for monitoring environmental changes. This study applies Convolutional Neural Networks (CNNs) and Sentinel-2 imagery to map deforestation from 2018 to 2024 using the U-Net architecture. Preliminary results show good accuracy in automated detection, supporting environmental monitoring and sustainable planning.*

Resumo. *O desmatamento na Região Tocantina exige novas formas de monitoramento de mudanças ambientais. Esta pesquisa aplica Redes Neurais Convolucionais (CNNs) e imagens Sentinel-2 para mapear desmatamento entre 2018 e 2024, com base na arquitetura U-Net. Resultados preliminares indicam boa precisão na detecção automática, apoiando o monitoramento e o planejamento sustentável.*

1. Introdução

A intensificação do desmatamento na Região Tocantina, situada na zona de transição entre os biomas Cerrado e Amazônia, representa uma ameaça crítica à integridade ecológica e hídrica do território. Dados recentes apontam que, somente em maio de 2023, Maranhão e Tocantins responderam por 60% do desmatamento no Cerrado brasileiro [IPAM 2023]. A velocidade com que essas transformações ocorrem demanda novas tecnologias de detecção contínua e automatizada.

Modelos tradicionais de monitoramento, como o PRODES e o DETER, ainda são essenciais, mas apresentam limitações quanto à resolução temporal e espacial. A integração de imagens multiespectrais de satélite com algoritmos de aprendizado profundo, especialmente CNNs, tem se mostrado uma alternativa eficaz, precisa e escalável [Md Jelas et al. 2024, Ortega Adarme et al. 2020].

A proposta deste estudo é desenvolver uma abordagem baseada em análise multitemporal com dados Sentinel-2 e Redes Neurais Convolucionais para detectar mudanças sucessivas na cobertura florestal na Região Tocantina entre os anos de 2018 a 2024. Neste trabalho, o termo “análise multitemporal” refere-se ao uso de mosaicos anuais derivados de imagens Sentinel/Landsat de diferentes anos, permitindo observar a dinâmica da cobertura florestal ao longo do tempo e não apenas em um instante isolado.

2. Referencial Teórico

As Redes Neurais Convolucionais (CNNs) são especialmente eficazes em tarefas de segmentação semântica, por sua capacidade de extrair e generalizar padrões espaciais a partir de imagens [Md Jelas et al. 2024]. A arquitetura U-Net, em particular, destaca-se

por seu desempenho em cenários com conjuntos de dados limitados, sendo amplamente adotada em aplicações de sensoriamento remoto [Md Jelas et al. 2024, Ortega Adarme et al. 2020, Masolele et al. 2022].

A combinação de séries temporais com dados multiespectrais permite observar a evolução do uso da terra ao longo do tempo, melhorando a detecção de mudanças sutis ou gradativas, como aquelas associadas ao avanço do desmatamento [Zhao et al. 2023]. Estudos mostram que a utilização integrada de dados ópticos e radar (SAR), bem como o uso de plataformas como o Google Earth Engine, tem ampliado a capacidade de monitoramento em ambientes tropicais com menor custo computacional [Arévalo et al. 2020, FSC.org 2020].

3. Metodologia

Esta pesquisa, atualmente em desenvolvimento, propõe uma abordagem baseada em redes neurais convolucionais (CNNs) aplicadas a imagens multitemporais do satélite Sentinel-2, com o objetivo de detectar áreas desmatadas na Região Tocantina ao longo do período de 2018 a 2024. A metodologia foi adaptada de estudos anteriores que aplicam técnicas de segmentação semântica ao sensoriamento remoto, com destaque para os trabalhos de [Ortega Adarme et al. 2020] e [Arévalo et al. 2020].

O processo metodológico iniciou-se com a delimitação da área de estudo, priorizando municípios da Região Tocantina com maiores índices de desmatamento, conforme dados recentes do IPAM [IPAM 2023]. Municípios como Balsas (MA) e Rio do Sono (TO) foram selecionados por representarem zonas críticas de pressão antrópica sobre a vegetação nativa. Essa seleção busca garantir que o modelo seja treinado e validado em contextos reais e desafiadores.

Em seguida, realizou-se a aquisição de imagens ópticas Sentinel-2, com resolução de 10 metros, disponíveis gratuitamente pelo programa europeu Copernicus. O intervalo temporal adotado abrange sete anos (2018–2024), permitindo uma análise contínua da dinâmica de cobertura do solo. Foram priorizadas imagens obtidas nos períodos de seca, com menor interferência de nuvens, visando melhorar a visibilidade da vegetação e do solo exposto.

As imagens foram então pré-processadas na plataforma Google Earth Engine, que oferece ferramentas eficientes para manipulação de dados em escala. As etapas incluíram o mascaramento de nuvens e sombras, o cálculo de índices espectrais, como NDVI (Normalized Difference Vegetation Index) e NDFI (Normalized Difference Fraction Index), e a composição de mosaicos multitemporais, de forma a representar a evolução da paisagem ao longo do tempo.

Para incorporar a dimensão temporal, foram utilizados mosaicos anuais compostos a partir de imagens Sentinel-2, cobrindo o período a definir. Esses mosaicos foram empilhados, permitindo que o modelo comparasse diferentes períodos (antes/depois) e identificasse padrões de conversão florestal ao longo do tempo.

Com os dados espectrais organizados, iniciou-se a preparação dos dados para o treinamento do modelo CNN. As imagens foram divididas em blocos (patches) de 256×256 pixels, padronizadas e associadas a máscaras de referência extraídas dos dados oficiais do PRODES/INPE. Essas máscaras, convertidas para formato binário, indicam

as classes "floresta" e "desmatamento", funcionando como rótulos para o aprendizado supervisionado.

A arquitetura de rede utilizada nesta etapa foi a U-Net, amplamente empregada em segmentação de imagens geoespaciais devido à sua capacidade de capturar tanto detalhes locais quanto contextos globais [Md Jelas et al. 2024, Ortega Adarme et al. 2020]. A implementação está sendo conduzida na linguagem Python, com suporte das bibliotecas TensorFlow e Keras, em ambiente com aceleração por GPU. Técnicas de data augmentation, como rotações e espelhamentos, são aplicadas para aumentar a variabilidade do conjunto de treinamento e melhorar a capacidade de generalização do modelo. O monitoramento do treinamento inclui early stopping e validação cruzada com partições geográficas.

Por fim, os resultados do modelo serão avaliados por meio de métricas quantitativas amplamente utilizadas na literatura, como F1-Score, Coeficiente Kappa, Acurácia Geral e Índice de Interseção sobre União (IoU). Também serão produzidos mapas temáticos para comparação visual com os dados oficiais, possibilitando uma análise espacial mais refinada da performance da rede. Essa etapa está em fase inicial, mas os primeiros experimentos indicam que a abordagem tem potencial para identificar tanto desmatamentos recentes quanto alterações cumulativas na paisagem. A Figura 1 a seguir ilustra o fluxo metodológico proposto nesta pesquisa.

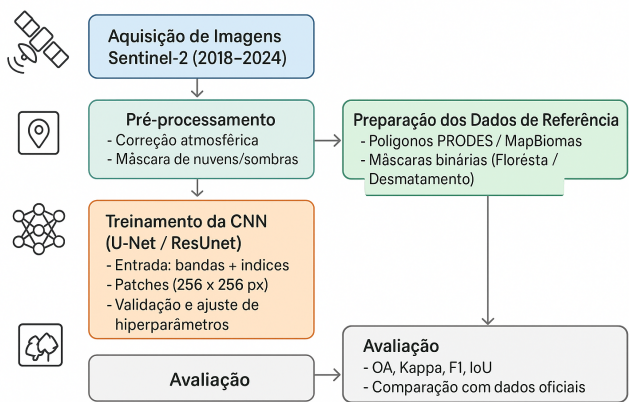


Figure 1. Fluxograma metodológico proposto para a detecção de desmatamento na Região Tocantina.

A metodologia adotada busca equilibrar rigor técnico e aplicabilidade prática, com vistas a desenvolver uma solução que possa ser replicada em outras regiões do MATOPIBA ou em biomas similares. O desenvolvimento contínuo da pesquisa permitirá o refinamento dos modelos e a inclusão de dados adicionais, como informações SAR (Sentinel-1), para ampliar a robustez da detecção em diferentes condições ambientais.

4. Resultados e Discussão

As composições multitemporais elaboradas para o período de 2018 a 2024 apresentaram excelente qualidade espectral, o que possibilitou a identificação de padrões consistentes de conversão florestal ao longo do tempo. A aplicação da arquitetura U-Net, treinada com

dados segmentados a partir das máscaras do PRODES, gerou resultados preliminares expressivos, com acurácia superior a 85% em áreas com desmatamento consolidado, especialmente onde há grandes polígonos de uso agropecuário.

Os mapas de classificação produzidos até o momento revelam que o modelo é capaz de detectar tanto episódios recentes de desmatamento quanto alterações acumuladas ao longo dos anos. Esse desempenho é particularmente evidente em regiões de fronteira agrícola em expansão. Além disso, o uso de séries temporais contribuiu significativamente para a redução de falsos positivos, problema frequente em análises baseadas em imagens isoladas, fortalecendo a robustez da abordagem proposta.

5. Conclusão e Trabalhos Futuros

A análise multitemporal com CNNs demonstrou ser uma abordagem viável e eficaz para o monitoramento ambiental na Região Tocantina. A combinação entre imagens Sentinel-2 e segmentação semântica por U-Net permite detectar com mais precisão alterações recorrentes na cobertura vegetal. Esta abordagem tem potencial para complementar os sistemas de monitoramento tradicionais, fornecendo subsídios técnicos a políticas públicas ambientais.

Como trabalhos futuros, pretende-se incorporar dados SAR (Sentinel-1), testar a generalização do modelo em outras regiões do MATOPIBA e publicar os resultados em plataformas abertas.

References

- Arévalo, P., Bullock, E. L., Woodcock, C. E., and Olofsson, P. (2020). A suite of tools for continuous land change monitoring in google earth engine. *Frontiers in Climate*, 2:576740.
- FSC.org (2020). Protecting forests with google earth engine. <https://fsc.org/en/newscentre/general-news/protecting-forests-with-google-earth-engine>.
- IPAM (2023). Tocantins e maranhão responderam por 60% do desmatamento do cerrado em maio. <https://ipam.org.br>. Acessado em: 25 ago. 2025.
- Masolele, R. N., De Sy, V., Marcos, D., Verbesselt, J., Gieseke, F., Mulatu, K. A., Moges, Y., Sebrala, H., Martius, C., and Herold, M. (2022). Using high-resolution imagery and deep learning to classify land-use following deforestation: a case study in ethiopia. *GIScience & Remote Sensing*, 59(1):1446–1472.
- Md Jelas, I., Zulkifley, M. A., Abdullah, M., and Spraggon, M. (2024). Deforestation detection using deep learning-based semantic segmentation techniques: a systematic review. *Frontiers in Forests and Global Change*, 7:1300060.
- Ortega Adarme, M., Queiroz Feitosa, R., Nigri Happ, P., Aparecido de Almeida, C., and Rodrigues Gomes, A. (2020). Evaluation of deep learning techniques for deforestation detection in the brazilian amazon and cerrado biomes from remote sensing imagery. *Remote Sensing*, 12(6):910.
- Zhao, C., Pan, Y., Zhu, X., Li, L., Xia, X., Ren, S., and Gao, Y. (2023). Monitoring of deforestation events in the tropics using multidimensional features of sentinel-1 radar data. *Frontiers in Forests and Global Change*, 6:57.