

MAPEAMENTO DO INCREMENTO ANUAL DE ESTRADAS NA AMAZÔNIA COM INTELIGÊNCIA ARTIFICIAL

Stefany Cristina Pinheiro Costa ¹, Jonas Botelho Jr. ², Julia Gabriela Ferreira Ribeiro ¹, Jailson Soares de Souza Filho ¹, Camila da Silva Damasceno ¹, Bruno Gama Ferreira ¹, Carlos Moreira de Souza Jr. ¹

¹Instituto do Homem e Meio Ambiente da Amazônia - Imazon
Trav. D. Romualdo de Seixas, 1698, Ed. Zion Business, 11º andar - Belém - PA, Brasil
{stefany.pinheiro, juliagabriela, jailson, camila, bruno, souzajr}@imazon.org.br;

²Missouri State University
901 S National Ave, Springfield, Missouri, 65897
jonasjunior@gmail.com

RESUMO

Identificar e mapear a expansão de estradas na Amazônia é o passo inicial para monitorar a ocupação da região. A rede de estradas não oficiais é considerada um dos principais vetores do desmatamento na Amazônia. Existem métodos semi-automáticos e automáticos já testados para detectar estradas não oficiais na Amazônia. Recentemente, um algoritmo de Inteligência Artificial (IA) usando o modelo U-Net foi aplicado com sucesso para detectar e mapear estradas na Amazônia. Contudo, o monitoramento do incremento anual com IA ainda não foi implementado. Este estudo teve como objetivo propor um método para monitorar o crescimento anual de estradas com IA. O método foi testado no período de 2020 a 2022 em regiões da Amazônia com padrões distintos de estradas. Este estudo aponta que a detecção do incremento anual de estradas com IA tem o potencial de ser usado no monitoramento de estradas, adicionando agilidade e maior precisão no mapeamento.

Palavras-chave — Estradas, Amazônia, monitoramento, inteligência artificial, Google Earth Engine.

ABSTRACT

Identifying and mapping the expansion of roads in the Amazon is the initial step in monitoring the region's occupation. The network of unofficial roads is considered one of the main drivers of deforestation in the Amazon. There are already tested semi-automatic and automatic methods to detect unofficial roads in the Amazon. Recently, an Artificial Intelligence (AI) algorithm using the U-Net model was successfully applied to detect and map roads in the Amazon. However, annual increment monitoring with AI still needs to be implemented. This study proposed a method to monitor annual road increments with AI. The method was tested from 2020 to 2022 in Amazon regions with distinct road patterns. This study points out that detecting annual road increments with AI has the potential to be used in road monitoring, adding agility and greater accuracy in mapping.

Key words — Roads, Amazon, Monitoring, Artificial Intelligence, Google Earth Engine.

1. INTRODUÇÃO

O processo de ocupação da Amazônia tem ocorrido através da abertura de estradas. Dois tipos de estradas já foram identificadas, quanto à autorização para sua construção: oficiais e não-oficiais. Essas estradas definem três padrões na paisagem: dendrítico, geométrico e espinha de peixe [1].

Inicialmente, o mapeamento de estradas era realizado de forma manual por meio da interpretação visual [2]. Dessa forma, tornando o mapeamento oneroso e mais demorado. O uso de inteligência artificial (IA) tornou esse processo mais rápido e menos custoso, automatizando a detecção de estradas oficiais e não-oficiais na Amazônia [3]. Até 2020, o mapeamento utilizando IA detectou um total de 3,46 milhões de quilômetros de estradas, com 41% da floresta remanescente atravessada por estradas, com uma acurácia de 70% [3]. Os autores apontaram que a acurácia da detecção de estradas com IA detectou mais estradas do que os dados de referência usado na análise [3].

Analisar a expansão de estradas na Amazônia é essencial para compreender a ocupação da região e o surgimento de atividades não autorizadas, como extração madeireira e garimpos, e ameaças às Áreas Protegidas. A rede de estradas não-oficiais é considerada um dos vetores principais do desmatamento na Amazônia - onde 95% do desmatamento na região ocorre dentro de até 5,5 quilômetros das estradas [4]. Portanto, é necessário que haja monitoramento de novas estradas não-oficiais. Mesmo com os avanços recentes de mapeamento de estradas com IA na Amazônia, ainda não existe um método de monitoramento do incremento anual de estradas. Nesse estudo, propomos uma metodologia para automatizar o monitoramento anual das estradas na Amazônia, utilizando como base o método de detecção com IA proposto por Botelho et al. [3]. O método de detecção de incremento anual de estradas foi testado em três áreas pilotos e apresentou o mesmo nível de precisão, com a vantagem de só detectar os novos segmentos de estradas. Apresentamos nas seções abaixo a metodologia e os resultados em três

áreas piloto da Amazônia, com padrões e história de ocupação distintos.

2. MATERIAL E MÉTODOS

2.1 Área de estudo

A área de estudo corresponde a três cartas da base cartográfica do IBGE, na escala de 1:250.000 (SC-19-X-D, SB-21-Z-A, SC-22-V-C), na Amazônia Legal. As cartas cortam os estados do Acre, Amazonas, Mato Grosso, Pará e Rondônia (Figura 1). Nessas áreas pilotos, há ocorrência predominante dos padrões dendríticos e geométricos das estradas [1]. Além disso, há presença de atividades relacionadas ao uso de recursos naturais, como pecuária, agricultura, exploração madeireira e garimpo.

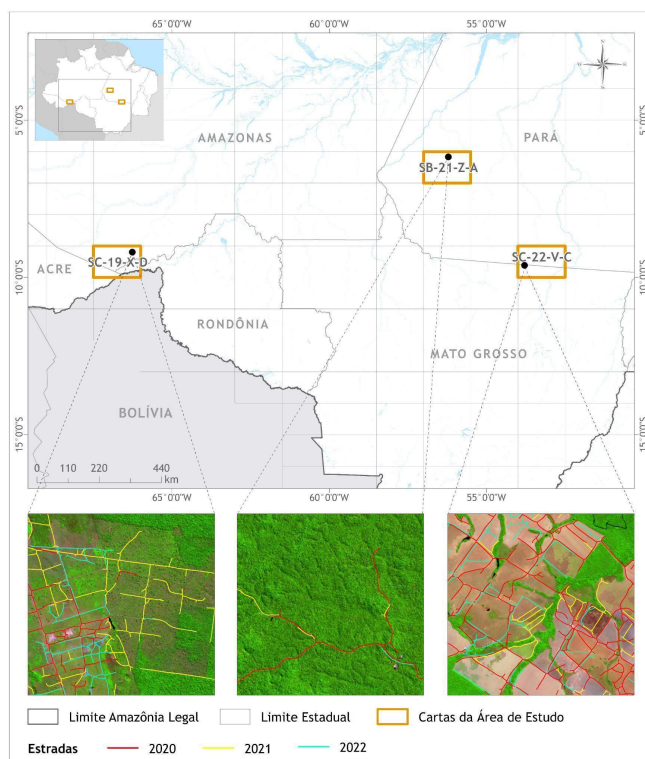


Figura 1. Mapa das cartas SC-19-X-B, SB-21-Z-A e SC-22-V-C, áreas piloto do estudo.

2.2 Mosaicos Sentinel-2

Para a construção dos mosaicos, foram utilizadas imagens Sentinel-2 para o ano de 2021 e 2022, obtidas através do Google Earth Engine [5]. As imagens foram escolhidas com base na localização da área de estudo e nos filtros de cobertura de nuvem, bandas espectrais e data. As bandas *SWIR-1*, *NIR* e *Red* por apresentarem maior contraste espectral das estradas, tradicionalmente usados para monitorar estradas com interpretação visual [2, 7].

2.3 Mapa de estradas com incremento anual.

A metodologia desenvolvida para o mapeamento do incremento anual de estradas está resumida na Figura 2. Detalhes sobre o modelo de IA para detecção de estradas já foram publicados (ver [3]). O método é baseado na rede neural convolucional (RNC) U-NET [8] através dos seguintes passos: (i) os dados mapeados manualmente [2] serviram de base para seleção das amostras de treino, teste e calibração do modelo; (ii) foi verificada a melhor iteração do modelo na 17ª época, sendo escolhida com base no menor resultado da função de perda (*soft dice*) e (iii) o modelo de IA final foi utilizado para mapear todas as estradas na Amazônia até o ano de 2020.

Neste estudo, desenvolvemos um método de detecção e mapeamento do incremento anual de estradas. Primeiramente, os mosaicos gerados através do GEE, foram exportados para o ambiente de nuvem da Google - Google Cloud Storage (GCS). O armazenamento em ambiente de nuvem permite que haja maior comunicação entre as diferentes etapas, uma vez que os dados em nuvens de computadores podem ser acessados tanto no ambiente de execução, quanto no ambiente de processamento geoespacial. Nesta etapa o modelo faz a leitura dos dados armazenados para fazer a predição de novas estradas. A etapa de predição é realizada no Google Colab e a saída do processo de predição é salvo no GCS.

Comparamos o mapa inicial de estradas, gerado pelo algoritmo de IA, com o dado do ano subsequente após a predição das novas estradas. Para isso, o dado do ano anterior é subtraído do dado atual retornando apenas o incremento, ou seja, onde identificamos novos segmentos de estradas. Contudo, o dado subtraído apresenta ruídos que não representam necessariamente o incremento de estradas.

Para remover os segmentos que não constituem incremento de estradas, aplicamos um filtro espacial. A etapa de aplicação do filtro espacial é realizada no GEE. Primeiro, é feito o agrupamento em conjunto de 100 pixels conectados que formam objetos. Assinalamos a cada objeto na imagem um identificador único, e calculamos a área de cada objetivo. Em seguida, definimos a área mínima na qual o objeto possui um segmento que não faz parte de uma estrada. A escolha da área mínima foi empírica baseada em interpretação visual, ou seja, os objetos com até 10 hectares no qual foi possível remover os ruídos de não incremento, além de não remover a informação necessária para exportar o incremento.

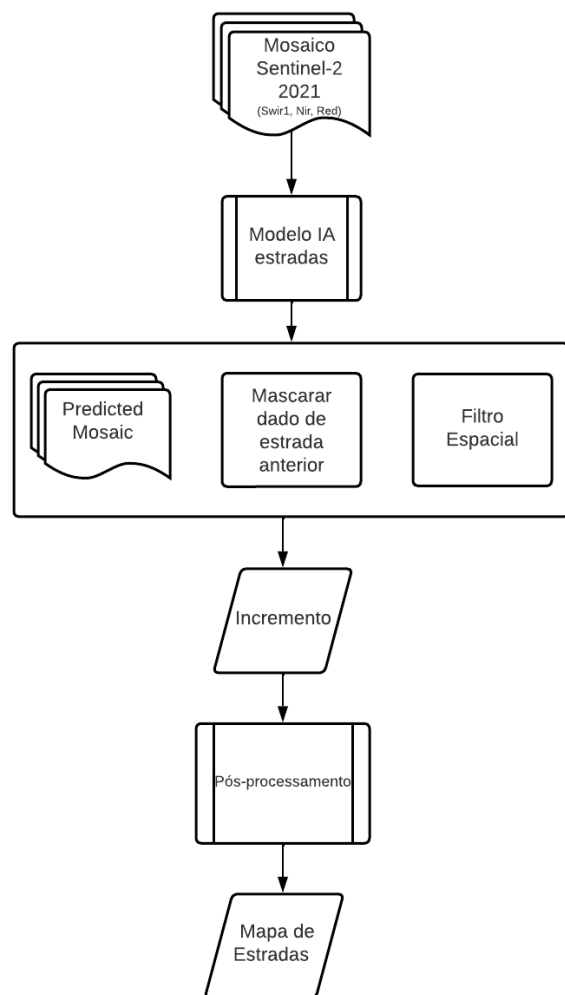


Figura 2. Fluxo para mapear incremento de estradas.

Após filtragem do incremento anual, o dado é armazenado no GCS para a etapa de pós-processamento [3]. Essa etapa é realizada no Google Colab, utilizando bibliotecas para o processamento de dados geoespaciais. No final, incremento processado de forma matricial é convertido para o formato vetorial, para estimar a linha central das estradas, e estimar a extensão e conectividade entre os segmentos. Essa etapa também remove possíveis ruídos que não foram removidos na etapa anterior, como pequenos segmentos desconectados, bordas das cenas das imagens e feições lineares que não representam estradas.

3. RESULTADOS

Observamos um aumento de mais de 30% de extensão de estradas nas áreas pilotos em 2021. A carta SB-21-Z-A apresentou maior incremento da extensão de 2.474,92 km (61%), com padrão predominantemente geométrico e dendrítico. Nas cartas SC-22-V-C e SC-19-X-D, o

incremento foi 815,14 km e 7.972,92 km, respectivamente (40% e 46%). As áreas piloto apresentaram mais de 35% de aumento na extensão de estradas em relação ao ano anterior (tabela 1).

Extensão de estradas (km)

Carta	Até 2020	2021	2022	Total 2021 a 2022
SC-22-V-C	2.022,51	815,14	349,38	1.164,52
SC-19-X-D	17.056,6	7.972,92	3.090,47	11.063,4
SB-21-Z-A	3.994	2.474,65	1.358,74	3.833,4

Tabela 1. Resultado do incremento de estradas.

Em 2022, a carta SC-22-V-C apresentou um incremento de 349 km (12% em relação ao total em 2021) de estradas; na carta SC-19-X-D o incremento foi de 3.090 km (12%) e na SB-21-Z-A de 1.358 km (21%) (tabela 1).

A carta SB-21-Z-A apresentou um incremento total expressivo de estradas comparando 2020 e 2022. Isto resultou em um acréscimo de 3.833 km de extensão de estradas para os dois anos – quase a mesma extensão mapeada na área até 2020 (3.994 km). Na carta SC-19-X-D, houve um total de 11.063 km - somando os anos de 2021 e 2022 - comparado ao ano de 2020. Na carta SC-22-V, a extensão total para os dois anos seguintes foi de 1.164 km de estradas.

Os resultados demonstram que o método proposto tem o potencial para ser aplicado em um sistema de monitoramento anual de estradas na Amazônia.

4. DISCUSSÃO

Algoritmos de IA têm sido amplamente utilizados em várias áreas do sensoriamento remoto. Os usos dessas tecnologias contribuem para otimizar o monitoramento de áreas extensas, como a Amazônia. Avanços recentes no mapeamento de estradas na Amazônia com IA [3] mostram-se promissores para a operacionalização do monitoramento anual das estradas. Neste estudo, testamos um método para esta finalidade. O algoritmo foi testado com sucesso em três áreas pilotos e tem o potencial para ser escalado para o monitoramento anual de estradas na Amazônia.

O monitoramento será importante, uma vez que as estradas antecedem o desmatamento, a exploração madeireira e são os principais vetores de ocupação de terras públicas não destinadas na Amazônia. Além disso, as estradas são uma das principais variáveis preditoras de risco de desmatamento [6], como no modelo da PrevisIA.

O monitoramento anual de estradas também é relevante para a identificação rápida de padrões espaciais de estradas, o que está associado ao tipo de atividade antrópica

responsável pela sua abertura (e.g., o padrão dendrítico é geralmente associado à exploração madeireira).

5. CONCLUSÕES

O método proposto neste estudo detectou e mapeou com sucesso o incremento de estradas anual nas áreas piloto, com o mesmo nível de detecção do método de IA. Os resultados da sua aplicação em três áreas piloto da Amazônia demonstraram uma tendência de expansão contínua de estradas, o que implica na necessidade de um monitoramento anual, e combate a sua expansão. Essas informações podem auxiliar também na análise e entendimento da ocupação da Amazônia e complementar os sistemas de monitoramento da Amazônia. Os próximos passos deste estudo incluem a classificação dos tipos de estradas, a análise de acurácia da detecção do incremento anual e a implementação do sistema de monitoramento de estradas da Amazônia. Além disso, o método proposto tem o potencial de ser aplicado em outros biomas brasileiros e em outras regiões de florestas tropicais

6. AGRADECIMENTOS

Agradecemos ao Fundo Vale, referente ao contrato TCT 003/2022, e à Fundação Climate and Land Use Alliance - CLUA referente ao contrato G-2008-57051.

7. REFERÊNCIAS

- [1] ARIMA, Eugenio Y. et al. Explaining the fragmentation in the Brazilian Amazonian forest. *Journal of Land Use Science*, v. 11, n. 3, p. 257-277, 2016.
- [2] BRANDÃO JR, A. O.; SOUZA JR, C. M. Mapping unofficial roads with Landsat images: a new tool to improve the monitoring of the Brazilian Amazon rainforest. *International Journal of Remote Sensing*, v. 27, n. 1, p. 177-189, 2006.
- [3] BOTELHO JR, Jonas et al. Mapping Roads in the Brazilian Amazon with Artificial Intelligence and Sentinel-2. *Remote Sensing*, v. 14, n. 15, p. 3625, 2022.
- [4] BARBER, Christopher P. et al. Roads, deforestation, and the mitigating effect of protected areas in the Amazon. *Biological conservation*, v. 177, p. 203-209, 2014.
- [5] GORELICK, Noel et al. Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote sensing of Environment*, v. 202, p. 18-27, 2017.
- [6] SALES, Marcio et al. A spatiotemporal geostatistical hurdle model approach for short-term deforestation prediction. *Spatial Statistics*, v. 21, p. 304-318, 2017.

[7] NASCIMENTO, Eric de Souza et al. Roads in the Southwestern Amazon, State of Acre, between 2007 and 2019. *Land*, v. 10, n. 2, p. 106, 2021.

[8] RONNEBERGER, Olaf; FISCHER, Philipp; BROX, Thomas. U-net: Convolutional networks for biomedical image segmentation. In: *International Conference on Medical image computing and computer-assisted intervention*. Springer, Cham, 2015. p. 234-241.