

Mapeamento de Corte Seletivo na Amazônia Brasileira Usando Imagens Planet de Alta Resolução Espacial e Inteligência Artificial: estudo de caso na Floresta Nacional do Jamari

Daniel Braga¹, Ricardo Dalagnol^{2,3,4}, Celso B. M. Ribeiro⁵, Liana O. Anderson⁶, Luiz E.O.C. Aragão²

¹Departamento de Geociências – Universidade Federal de Juiz de Fora (UFJF)

Caixa Postal 20010 – 36036-900 – Juiz de Fora – MG – Brazil

²Department of Computer Science – Instituto Nacional de Pesquisas Espaciais (INPE)

São José dos Campos – SP - Brazil

³NASA-Jet Propulsion Laboratory, California Institute of Technology, Pasadena, CA 91109, USA.

⁴Center for Tropical Research, Institute of the Environment and Sustainability, University of California, Los Angeles, Los Angeles, CA 90095, USA.

⁵Departamento de Engenharia Sanitária e Ambiental - Universidade Federal de Juiz de Fora (UFJF), Caixa Postal 20010 – 36036-900 – Juiz de Fora – MG – Brazil

⁶National Centre for Monitoring and Early Warning of Natural Disasters (CEMADEN), São José dos Campos, São Paulo, Brazil

daniel.braga@ich.ufjf.br, ricds@hotmail.com, celso.bandeira@ufjf.edu.br,
liana.anderson@gmail.com, luiz.aragao@inpe.br

Abstract. *The Amazon has the largest remnant of tropical forests in the world and is being threatened daily by deforestation and forest degradation. The estimated area of forest degradation is underestimated, which is problematic for both sustainable policy enforcement, environmental oversight and national carbon emission inventories. Therefore, a deep learning model (U-Net) was trained to map forest degradation using Planet imagery (4.77 m spatial resolution) in the Jamari National Forest at the Brazilian Amazon. Preliminary results showed an overall accuracy of 67%. Our approach is promising to monitor forest concessions in Amazonia.*

Resumo. *A Amazônia possui o maior remanescente de florestas tropicais do mundo e está sendo ameaçada diariamente pelo desmatamento e degradação florestal. A área estimada de degradação florestal é subestimada, o que é problemático tanto para a aplicação de políticas sustentáveis, fiscalização ambiental e inventários nacionais de emissões de carbono. Dessa forma, um modelo de deep learning (U-Net) foi treinado para mapear a degradação florestal usando imagens Planet (resolução espacial de 4,77 m) na Floresta Nacional do Jamari, na Amazônia brasileira. Os resultados preliminares mostraram precisão geral de 67%. Nossa abordagem é promissora para monitoramento de concessões florestais na Amazônia.*

1. INTRODUÇÃO

Estima-se que aproximadamente 17% das florestas tropicais desapareceram desde 1990 (VANCUTSEM et al., 2021). Embora a vegetação amazônica ainda abranja oito dos treze países da América do Sul, sua cobertura original sofreu severa redução por conta de processos como o desmatamento e a degradação florestal a partir da década de 1970, principalmente pela inauguração da rodovia Transamazônica (FEARNSIDE, 2005). Os

processos de degradação afetam a Amazônia em larga escala e já ultrapassam as áreas afetadas por desmatamento (MATRICARDI et al., 2020).

A degradação florestal é caracterizada principalmente por diversos padrões espaciais como: a abertura de estradas na floresta; o corte de árvores; clareiras, tanto das árvores extraídas quanto de outras árvores mortas durante o processo; “cicatrizes” de incêndios; e pátios de extração (PINHEIRO et al., 2016). Dados recentes obtidos do *Tropical Moist Forest* (TMF) do *Joint Research Centre* (JRC) apresentam que a área anual da Amazônia que sofreu com desmatamento e degradação aumentou 24% entre 2019 e 2020 na Amazônia Legal Brasileira, indo de 17.303 km² para 21.379 km² (BEUCHLE et al. 2021). Em adição, as emissões de carbono ainda não são devidamente mensuradas e relatadas nos inventários de emissão de carbono dos países amazônicos (SILVA JUNIOR, et al., 2021).

O objetivo da pesquisa foi avaliar o mapeamento do corte seletivo gerado por um modelo de deep learning para a Floresta Nacional do Jamari, através de imagens de alta resolução espacial Planet. Neste estudo são apresentados os resultados preliminares do mapeamento e a avaliação do desempenho do modelo para mapeamento do corte seletivo relacionado ao manejo florestal.

2. METODOLOGIA

2.1 Área de estudo

A área de estudo foi a Floresta Nacional do Jamari, que pertence à Amazônia Legal e está localizada no norte do estado de Rondônia, entre os municípios de Cujubim, Candeias do Jamari e Itapoã do Oeste (Figura 1). Composta por espécies de árvores de alto valor comercial, sua vegetação ombrófila densa e aberta cobre aproximadamente 2200 km², dos quais cerca de 960 km² (44%) foram inicialmente destinados para a concessão florestal em 2008 (DALAGNOL et al., 2019). É importante reiterar que desde a década de 1980 a área sofre pressão de empreendimentos minerários e da agropecuária, assim como da criação de assentamentos da reforma agrária, o que modificou severamente a paisagem local (BASTOS et al., 2017).

O mapeamento de degradação nesta área seria capaz de identificar processos recorrentes como a abertura de estradas, o corte legal e ilegal, efeitos de borda, queimadas e o próprio desmatamento. As concessões florestais na Amazônia são formas de exploração da floresta na Amazônia de uma forma mais sustentável. Um dos exemplos delas é a Floresta Nacional do Jamari, no estado de Rondônia, a primeira concessão florestal da Amazônia. O monitoramento dessas atividades é importante para garantir que não haja uma exploração além do estabelecido pelo plano de manejo.




Figura 1 - Limite da área de estudo (Floresta Nacional do Jamari). Imagem no *background* é uma composição colorida cor-verdadeira do satélite Planet produto NICFI.

2.2 Aquisição de imagens Planet e fotointerpretação

O uso de imagens de alta resolução espacial possibilita a fotointerpretação das feições de extração de madeira e queimadas com maior detalhamento. Nesse sentido, a constelação de satélites da missão Planet fornece imagens de alta resolução espacial (~3 – 5 m) e alta revisita (~1 – 3 dias) através do uso de uma constelação (>100) de satélites tipo DOVE (*Digital Orbiting Voice Encoder*). Nesse estudo foram utilizadas as imagens do programa NICFI (*Norway's International Climate and Forest Initiative*) (HERMANSEN et al., 2017), que disponibilizou imagens Planet de alta resolução espacial por meio de um mosaico das florestas tropicais. Foram utilizados mosaicos bi-anuais (6 meses) de 2016 a 2021 para o mapeamento.

Para treinar o modelo, amostras de corte seletivo foram fotointerpretadas na Flona Jamari, bem como em concessões florestais no estado do Mato Grosso. Um total de 289 *quads* ou *tiles* Planet (20x20 km) foram fotointerpretados. Nesse processo, foram utilizadas composições de cor verdadeira (RGB), e o índice de vegetação VARI (Índice Resistente à Atmosfera na Região Visível) (GITELSON et al., 2002). O VARI representa a quantidade de verde na vegetação, calculados a partir de áreas com maior ou menor estresse na vegetação (Equação 1). Ele destaca as áreas com solo exposto ou com dano no dossel da floresta, permitindo mapear as áreas de corte seletivo.

$$VARI = (G - R) / (G + R - B) \quad (1)$$

Equação 1. "VARI" = Índice de Vegetação Resistente à Atmosfera na Região do Visível; "G", "R" e "B" consistem nas bandas do verde, vermelho e azul, respectivamente (Gitelson et al., 2002).

2.3 Modelo Deep Learning

Para realizar a segmentação semântica das áreas de degradação florestal usando imagens Planet, utilizou-se o modelo de redes neurais convolucionais U-Net (RONNEBERGER et al., 2015) aplicado em ambiente R (BUNN, KORPELA, 2014) através do *framework tensorflow* (GOLDSBOROUGH, 2016; RAMPASEK, GOLDENBERG, 2016). O *input* do modelo foram imagens de 256x256 pixels (*patches*) contendo as bandas Planet (R, G, B, NIR) e a máscara de degradação previamente delineada. A partir da amostragem, obteve-se 73.744 *patches* de treinamento. Na arquitetura da U-Net, em cada nível, têm-se duas camadas de convolução com janelas / *kernel* de tamanho 3x3 e um número de atributos que aumenta de acordo com a profundidade da rede até o centro. As camadas convolucionais analisam e aprendem padrões nessas janelas de *pixels* ao mesmo tempo, ao invés de *pixels* individuais. Dessa forma, o modelo é capaz de aprender padrões espaciais relacionados à degradação. O *output* final do modelo é a probabilidade de cada pixel ser caracterizado como extração de madeira. Usando essa probabilidade, obteve-se mapas binários, considerando um limiar maior que 0.5 para áreas afetadas pela exploração. Após treinado, o modelo teve como objetivo realizar a predição de áreas degradadas a partir do treinamento do modelo com padrões espaciais de degradação florestal. O modelo foi utilizado para prever o corte seletivo anualmente entre 2016 e 2021 para a Flona do Jamari.

2.4 Validação do mapeamento

Para validar o mapeamento das áreas manejadas na Flona do Jamari, foram compilados dados de referência sobre as concessões florestais obtidas no site do Serviço Florestal Brasileiro. Esses dados consistiram em polígonos das áreas manejadas com o ano do manejo (Figura 2). Essas informações foram cruzadas com o mapeamento automático para realizar uma avaliação visual e também quantitativa através de uma matriz de confusão. Calculou-se a acurácia global entre o mapeamento e a referência. Foi calculada a área total mapeada como corte seletivo dentro da Flona Jamari, para áreas dentro e fora das concessões florestais.

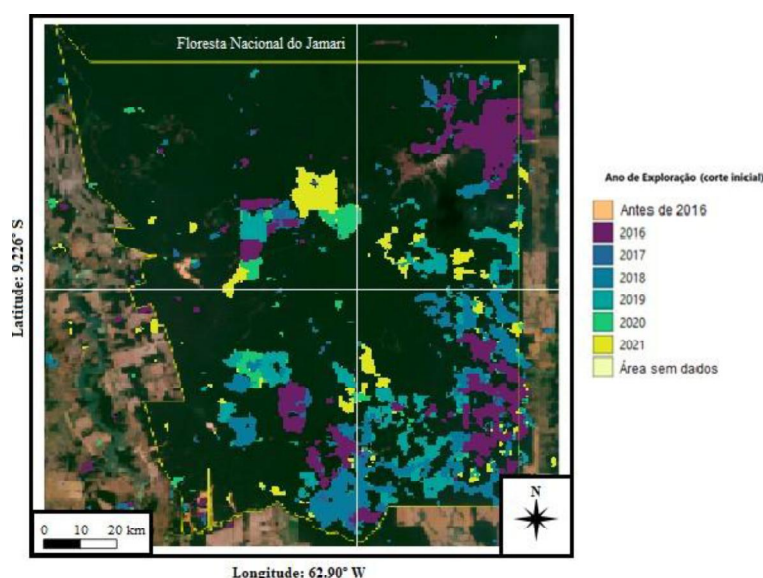


Figura 2 - Unidades de produção (UPA) de concessões florestais na Flona Jamari. Fonte de dados: Serviço Florestal Brasileiro, 2022.

3. RESULTADOS E DISCUSSÃO

3.1 Mapeamento

O modelo gerou um mapa de corte seletivo para a Floresta Nacional do Jamari durante o período de 2016 a 2021 (Figura 3). Nesse mapa, foi possível identificar a localização da extração de madeira por toda extensão da Flona, de acordo com a data em que ocorreu o corte segundo a disponibilidade das imagens Planet. Cada cor representa o ano em que o corte foi detectado pelo modelo. As 9 UPAs com data de corte na referência oficial entre 2016 e 2019 foram corretamente identificadas pelo modelo na mesma data do corte observado em campo, ou com alguma diferença mensal devido ao fato de as imagens Planet geradas antes de Setembro de 2020 serem mosaicos semestrais. As UPAs com ano de corte anterior à 2016 o modelo não foi capaz de identificar, uma vez que as imagens Planet ainda não estavam disponíveis.




Figura 3 – Mapa de predição de corte seletivo na Flona do Jamari. Cada cor corresponde a um ano de corte.

Como esperado, o modelo não detectou as UPAs com data de corte na referência oficial anterior a 2016, uma vez que o imageamento se inicia a partir de dezembro de 2015.

O modelo detectou a presença significativa de padrões de corte seletivo em 27 UPAs que não possuem nenhuma referência do SFB, que estão na categoria “Área não explorada / Sem dados” (Figura 4). A UPA da UMF I apresenta padrão de corte semelhante ao das UPAs com referência, as UPAs da UMF II apresentam padrão divergente do que foi observado no corte seletivo e as UPAs da UMF III variam entre as duas opções. O modelo também detectou áreas de corte seletivo dentro do perímetro de UPAs que não tinham informação de corte. Essas áreas apresentaram padrões de corte seletivos semelhantes ao de UPAs com referência. Esses padrões consistiram na ocorrência de trilhas regulares, pátios para estocagem de madeira espaçados, e clareiras no dossel da floresta.

O modelo detectou áreas de corte seletivo fora do perímetro de UPAs sem referência oficial do SFB, com padrões de corte diferente do observado no corte seletivo dentro das UPAs. Esses padrões consistiram na abertura de diversas trilhas desordenadas dentro da floresta na parte sudoeste, e sem ocorrência regular de pátios para estocagem da madeira. Essas áreas provavelmente consistem em cortes ilegais.

3.2 Análise quantitativa do mapeamento

Para uma análise estatística do mapeamento, foi gerada uma matriz de confusão (Tabela 1) a partir do cruzamento entre a predição do modelo U-Net e a referência do SFB. Os números representam a quantidade de pixels encontrados entre as classes de referência e predição. A partir da matriz de confusão, foi calculada uma exatidão global de 67%. Isso quer dizer que 67% da área foi corretamente mapeada de acordo com a referência do SFB.

Como apontado na análise visual, observamos que existem áreas que apresentaram padrões claros de corte seletivo, porém não tinham referência do ano do corte. Esse é o caso dos valores observados na coluna “0” (não detecção) onde são encontrados muitos pixels com predição entre 2016 até 2021. Uma parte dessas áreas ocorre por conta de possíveis inconsistências na referência do SFB que devem ser exploradas. Essa divergência reduz a exatidão global do modelo.

		Referência						
		0	2016	2017	2018	2019	2020	2021
Predição	0	6354	47	198	16	0	3	24
	2016	688	218	110	2	4	1	6
	2017	139	38	43	8	0	10	0
	2018	583	0	119	17	0	0	0
	2019	500	0	46	2	66	42	0
	2020	225	0	0	0	0	14	49
	2021	427	0	0	0	0	0	1

Tabela 1 – Matriz de Confusão entre a predição da extração de madeira e a referência oficial das datas de corte SFB. Nas linhas e colunas constam o ano da detecção ou valor=0, que corresponde à ausência do corte seletivo. As unidades correspondem a pixels Planet (4.77m).

O modelo identificou a presença de corte seletivo dentro do perímetro da UMFs e também fora destas, o que evidenciou perturbações relacionadas à degradação que não constam no banco de dados das concessões florestais do SFB. Foram detectados 513 km² (23,31%) de floresta com detecção de corte seletivo na Flona Jamari entre 2016 e 2021. Desse total de detecções, 58% foram identificados dentro das zonas de manejo, num total de 298 km², ou seja, 13,54% da área total da Flona.

4. CONSIDERAÇÕES FINAIS

O modelo aqui avaliado se mostrou promissor para identificação do corte seletivo de uma concessão florestal na Amazônia com uma exatidão global de 67%. Ele detecta padrões de corte seletivo, com abertura de estradas, pátios de estocagem de madeira e clareiras geradas pelo corte das árvores. Os resultados apresentam divergências nas métricas de avaliação estatísticas, que pode ser devido a inconsistências nos dados usados como referência.

Há dois tipos de áreas em que o modelo detectou a presença de degradação possivelmente ilegal: áreas de corte ilegal dentro das UPAs; e áreas de corte ilegal fora das UPAs. No primeiro caso, a extração ocorre aparentemente de forma desordenada, sugerindo

possível corte ilegal dentro das UPAs, uma vez que o padrão está diferente das UPAs que possuem referência de dados de corte. No segundo caso, o modelo detectou padrões de degradação e corte ilegal fora das UPAs, o que, assim como no primeiro caso, pode representar um sério problema na fiscalização e monitoramento das florestas públicas e nas concessões florestais. Sendo assim, por mais que o modelo detecte corretamente os padrões de degradação relacionados ao desmatamento, ainda é preciso validar algumas informações junto ao SFB, principalmente para a Floresta Nacional do Jamari.

5. REFERÊNCIAS

- BASTOS, A.; MANIESI, V.; GOMES, F. B.. Evolução do desmatamento e implicações ao uso e ocupação dos solos no entorno de unidades de conservação da Amazônia – o caso da floresta nacional do Jamari/RO. Os Desafios da Geografia Física na Fronteira do Conhecimento, p. 6612–24, 2017.
- BEUCHLE, R.; ACHARD, F.; BOURGOIN, C.; VANCUTSEM, C.; EVA, H. D.; FOLLADOR, M. Deforestation and Forest Degradation in the Amazon – Status and Trends up to Year 2020, EUR30727EN, Publications Office European Union, Luxembourg, 2021.
- BUNN, A.; KORPELA, M. Crossdating in dplR. 2014.
- DALAGNOL, R.; PHILLIPS, O. L.; GLOOR, E.; GALVÃO, L. S.; WAGNER, F. H.; LOCKS, C. J.; ARAGÃO, L. E. O. C.. Quantifying Canopy Tree Loss and Gap Recovery in Tropical Forests under Low-Intensity Logging Using VHR Satellite Imagery and Airborne LiDAR. Remote Sensing, v. 11, n. 7, p. 817, 2019.
- FEARNSIDE, P. M.. Deforestation in Brazilian Amazonia: history, rates, and consequences. Conservation Biology, v. 19, n. 3, p. 680-688, 2005.
- GITELSON, A. A.; ZUR, Y.; CHIVKUNOVA, O. B.; MERZLYAK, M. N.. Assessing Carotenoid Content in Plant Leaves with Reflectance Spectroscopy. Photochemistry And Photobiology, v. 75, n. 3, p. 272, 2002.
- GOLDSBOROUGH, P. A Tour of Tensorflow. 2016.
- HERMANSEN, E.; MCNEILL, D.; KASA, S.; RAJÃO, R.. Co-Operation or Co-Optation? NGOs' Roles in Norway's International Climate and Forest Initiative. Forests, v. 8, n. 3, p. 64, 2017.
- MATRICARDI, E. T.; SKOLE, D. L.; COSTA, O. B.; PEDLOWSKI, M. A.; SAMEK, J. H.; MIGUEL, E. P.. Long-term forest degradation surpasses deforestation in the Brazilian Amazon. Science, v. 369, n. 6509, p. 1378-1382, 2020.
- PINHEIRO, T. F.; ESCADA, M. I. S.; VALERIANO, D. M.; HOSTERT, P.; GOLLNOW, F.; MÜLLER, H.. Forest Degradation Associated with Logging Frontier Expansion in the Amazon: the BR-163 region in southwestern Pará, Brazil. Earth Interactions, v. 20, n. 17, p. 1-26, 2016.
- RAMPASEK, L.; GOLDENBERG, A. TensorFlow: biology's gateway to deep learning?. Cell Systems, v. 2, n. 1, p. 12-14, 2016.
- RONNEBERGER, O.; FISCHER, P.; BROX, T. U-Net: Convolutional Networks for Biomedical Image Segmentation. Em: NAVAB, N. et al. (Eds.). M I Computing and Comp-Assist Int – MICCAI. Springer International Publishing, v. 9351 p. 234–241, 2015.
- SILVA JUNIOR, C. H. L. et al. Amazonian Forest Degradation Must be Incorporated into the COP26 Agenda. Nature Geoscience, v. 14, n. 9, p. 634–635, 2021.
- VANCUTSEM, C.; ACHARD, F.; PEKEL, J.-F.; VIEILLEDENT, G.; CARBONI, S.; SIMONETTI, D.; GALLEGGO, J.; ARAGÃO, L. E. O. C.; NASI, R. Long-term (1990–2019) Monitoring of Forest Cover Changes in the Humid Tropics. Science Advances, 7 (10), 2021.