



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA, INOVAÇÕES E COMUNICAÇÕES
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

**MAPEAMENTO DE DEGRADAÇÃO FLORESTAL NA AMAZÔNIA BRASILEIRA
COM IMAGENS DE ALTA RESOLUÇÃO E INTELIGÊNCIA ARTIFICIAL:
ESTUDO DE CASO NA FLORESTA NACIONAL DO JAMARI**

Daniel Alves Braga

Relatório de Iniciação Científica do
programa PIBIC, orientada pelos
Dr. Luiz Eduardo Oliveira e Cruz de Aragão,
Dr.. Ricardo Dal’Agnol da Silva,
e Dr. Celso Bandeira.

INPE
SÃO JOSÉ DOS CAMPOS
2022



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA, INOVAÇÕES E COMUNICAÇÕES
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

**MAPEAMENTO DE DEGRADAÇÃO FLORESTAL NA AMAZÔNIA BRASILEIRA
COM IMAGENS DE ALTA RESOLUÇÃO E INTELIGÊNCIA ARTIFICIAL:
ESTUDO DE CASO NA FLORESTA NACIONAL DO JAMARI**

Daniel Alves Braga

Relatório de Iniciação Científica do
programa PIBIC, orientada pelos
Dr. Luiz Eduardo Oliveira e Cruz de Aragão,
Dr. Ricardo Dal’Agnol da Silva,
e Dr. Celso Bandeira.

INPE
SÃO JOSÉ DOS CAMPOS
2022

AGRADECIMENTOS

Utilizo desta seção para fazer um agradecimento especial ao coorientador Ricardo pela amizade construída durante o desenvolvimento da pesquisa e empenho nas reuniões semanais durante um ano.

Agradeço ao orientador Aragão e ao coorientador Celso por dar todo suporte necessário para execução do projeto.

Por fim, agradeço ao CNPQ por financiar a pesquisa, ao INPE por possibilitar essa experiência acadêmica incrível para mim e me inspirar cada dia mais a seguir esta carreira e ao grupo de pesquisa TREES por dialogar com nosso projeto e acreditar no nosso potencial.

RESUMO

A Amazônia possui o maior remanescente territorial de florestas tropicais do mundo e é diariamente ameaçada por processos antrópicos, tais como o desmatamento (corte raso) e a degradação florestal (corte de árvores e fogo). Nessa perspectiva, o objetivo deste estudo foi explorar o mapeamento da degradação florestal relacionada ao corte seletivo na Floresta Nacional (Flona) do Jamari em Rondônia, visto que existem concessões florestais e indícios de corte ilegal no território. Como o corte seletivo causa alterações mais sutis na floresta que um corte raso, o mapeamento deste fenômeno requer uso de imagens de satélite de maior resolução espacial e técnicas inovadoras para mapeamento em larga escala. Nesse sentido, a metodologia empregada consistiu no uso de imagens de alta resolução espacial (4.77 metros) obtidas da constelação de nanosatélites Planet (bandas R, G, B, NIR), para fotointerpretação de imagens e delimitação de padrões de degradação florestal ocasionados pela extração e corte de árvores durante o período de 2016 a 2021. Esse banco de dados vetoriais contribuiu para o treinamento de um modelo de redes neurais convolucionais U-Net, a fim de segmentar as feições de degradação. Para validação dos resultados, calculou-se uma matriz de confusão e exatidão global utilizando dados de campo disponibilizados pelo Serviço Florestal Brasileiro como referência oficial para áreas exploradas e não exploradas dentro da Flona. O modelo obteve precisão de 67% e apresentou detecções visualmente condizentes com a referência oficial para as áreas exploradas, assim como um alto número de feições de corte seletivo fora das Unidades de Manejo. Parte dos erros do modelo pode ser explicada: (1) modelo detectou áreas que não constavam nos dados de referência, mas que estavam aparentes nas imagens Planet (erro na referência oficial); (2) em algumas áreas o ano da detecção foi anterior ao da exploração devido à construção antecipada da infraestrutura usada para o manejo, como estradas. Foram detectados 513 km² de floresta com corte seletivo na Flona Jamari entre 2016 e 2021, dos quais 298 km² estavam dentro das zonas de manejo. As áreas detectadas fora das zonas de manejo podem consistir em atividades ilegais, que devem ser investigadas. Mais análises precisam ser realizadas para teste e validação do modelo, porém ele se mostra promissor para detecção da degradação florestal na Amazônia.

Palavras-chave: Amazônia. Degradação Florestal. Corte seletivo. Imagens de Alta Resolução. Deep Learning.

ABSTRACT

The Amazon has the largest territorial remnant of tropical forests in the world and is threatened daily by anthropic processes, such as deforestation (clear cutting) and forest degradation (tree cutting and fire). From this perspective, the objective of this study was to explore the mapping of forest degradation related to selective logging in the Jamari National Forest (Flona) in Rondônia, once there are forest concessions and evidence of illegal logging in the territory. As selective cutting causes more subtle changes in the forest than clear cutting, mapping this phenomenon requires the use of satellite images of higher spatial resolution and innovative techniques for large-scale mapping. In this sense, the methodology used consisted in the use of high spatial resolution images (4.77 meters) obtained from the Planet nanosatellite constellation (R, G, B, NIR bands), for the photointerpretation of images and delineation of patterns of forest degradation caused by the extraction and tree cutting during the period from 2016 to 2021. This vector database contributed to the training of a model of U-Net convolutional neural networks, in order to segment the degradation features. To validate the results, a confusion matrix and the global accuracy matrix calculated using field data provided by the Brazilian Forest Service as an official reference for explored and unexplored areas within the Flona. The model obtained an accuracy of 67% and presented detections visually consistent with the official reference for the explored areas, as well as a high number of selective cutting features outside the Management Units. Part of the model's errors can be explained: (1) the model detected areas that were not included in the reference data, but that were apparent in the Planet images (error in official reference); (2) in some areas the year of detection was earlier than that of exploration due to the anticipated construction of infrastructure used for management, such as roads. 513 km² of forest with selective cutting were detected in Flona Jamari between 2016 and 2021, of which 298 km² were within the management zones. Areas detected outside management zones may consist of illegal activities, which should be investigated. More analyzes need to be carried out to test and validate the model, but it shows promise for detecting forest degradation in the Amazon.

Keywords: Amazon. Forest Degradation. Selective Logging. High Resolution Images. Deep Learning.

LISTA DE FIGURAS

	<u>Pág.</u>
Figura 1	7
Evolução da área total degradada entre os anos de 1990-2019. Adaptado de Vancutsem et al. (2021)	
Figura 2	9
Focos e padrões de degradação florestal. Fonte: o autor.	
Figura 3	13
Exemplo de uma rede convolucional de três camadas. Adaptado de Dramsch (2020).....	
Figura 4	15
Arquitetura da rede U-net. Adaptado de Ronneberger et al. (2015) ...	
Figura 5	15
Exemplo de representação da função de ativação ReLU. Fonte: o autor.	
Figura 6	18
Mapa das UMFs da Flona do Jamari. Fonte: o autor.	
Figura 7	19
Fluxograma com as etapas do projeto. Fonte: o autor.	
Figura 8	20
Localização da Floresta Nacional do Jamari e seu limite. Fonte: o autor.	
Figura 9	22
Representação da degradação florestal por extração de madeira através de (1) composição cor verdadeira; e índice VARI com paletas de cores (2) r2g, e (3) puor. Fonte: o autor.	
Figura 10	22
Polígonos de presença de corte seletivo e quads da Planet. Fonte: o autor.	
Figura 11	25
Produto do modelo. Fonte: o autor.	
Figura 12	26
Compilação dos dados do SFB em forma de mapa de UPAs na Flona do Jamari. Fonte: o autor.	
Figura 13	27
Produto do modelo e UPAs nas quais o modelo identificou presença de corte seletivo. Fonte: o autor.	

SUMÁRIO

	<u>Pág.</u>
1 INTRODUÇÃO	1
1.1 Problema de Pesquisa.....	1
1.2 Objetivos.....	4
1.2.1 Objetivo geral.....	4
1.2.2 Objetivos específicos.....	4
2 DESENVOLVIMENTO	4
2.1 Revisão de Literatura	4
2.1.1 Degradação florestal na Amazônia	4
2.1.2 Monitoramento da degradação florestal por sensoriamento remoto	8
2.1.3 Detecção de alvos com imagens de sensoriamento remoto através do deep learning e redes neurais convolucionais	11
2.1.4 Concessão florestal e degradação na Floresta Nacional do Jamari	17
2.2 Materiais e Métodos	19
2.2.1 Seleção da área de estudo	19
2.2.2 Aquisição de imagens Planet	20
2.2.3 Índices de vegetação	21
2.2.4 Treinamento do modelo	23
2.2.5 Banco de dados das concessões florestais	23
2.2.6 Métricas estatísticas	24
3 CONCLUSÃO	25
3.1 Resultados	25
3.1.1 Mapeamento do corte seletivo	25
3.1.2 Comparação visual do mapeamento.....	26
3.1.3 Avaliação estatística da acurácia do mapeamento.....	28
3.1.4 Análise estatística de padrões de degradação na região de estudo.....	29
3.2 Discussão dos Resultados	29
REFERÊNCIAS BIBLIOGRÁFICAS	30

1. INTRODUÇÃO

1.1 Problema de Pesquisa

A Amazônia, maior floresta tropical do mundo, é capaz de armazenar a média de 120.000 Tg C, o que corresponde a cerca de 10% do carbono florestal global (HEINRICH et al., 2021). No entanto, 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). O principal impacto do desmatamento está relacionado à remoção da floresta e mudança de cobertura para pastagens de pecuária, campos de culturas agrícolas e áreas de mineração. Simultaneamente, os processos de degradação afetam a Amazônia em larga escala e já ultrapassam as áreas afetadas por desmatamento (MATRICARDI et al., 2020).

Nota-se que muitas florestas são inicialmente degradadas e posteriormente desmatadas (FEARNSIDE, 2005). A degradação pode ser resultante da exploração madeireira, incêndios (potencializados pelo corte seletivo) e efeitos da fragmentação florestal e formação de bordas florestais (FEARNSIDE, 2005). O processo de degradação florestal é caracterizado principalmente pela abertura de estradas na floresta, corte de árvores e clareiras, tanto das árvores extraídas quanto de outras árvores mortas durante o processo, e “cicatrices” 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 Brasileira¹, 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). Dessa forma, a degradação florestal na Amazônia está provavelmente sendo subestimada, o que

¹ Área formada pelos sete Estados da região Norte, mais parte do Estado do Maranhão e parte do Estado do Mato Grosso. Estende-se por mais de 300 milhões de hectares e abriga um terço da área do planeta ocupada por florestas tropicais úmidas (ÂNGELO; PEREIRA DE SÁ, 2007).

representa um obstáculo para a compreensão das consequências sobre o ciclo do carbono, clima regional, e biodiversidade de fauna e flora (ARAGÃO et al., 2008; SAMPAIO et al., 2007; PREVEDELLO et al., 2019; DECAËNS et al., 2018; VANCUTSEM et al., 2021).

Imagens de sensoriamento remoto são utilizadas em larga escala para identificação do desmatamento na Amazônia (MARTINS E SOUZA FILHO et al., 2006), porém a identificação de processos de corte de árvores e incêndios florestais causam efeitos muito mais sutis e efêmeros na vegetação e são mais difíceis de serem detectados. No passado, houve iniciativas relevantes para o mapeamento da degradação por corte seletivo com imagens do satélite Landsat (MATRICARDI et al., 2010; ASNER et al., 2002; ASNER et al., 2005; SOUZA; BARRETO, 2000). Contudo, imagens de mais alta resolução espacial (~5 m) ainda não haviam sido exploradas em nenhum sistema de monitoramento operacional.

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 (~5 m) e alta revisita (até diária) através do uso de uma constelação (>100) de satélites tipo DOVE (*Digital Orbiting Voice Encoder*), que ainda não foi profundamente explorada para detectar efeitos de degradação na floresta. Essa capacidade de monitoramento e área observada tem potencial para a visualização dos efeitos de degradação na floresta com maior abrangência e frequência que missões anteriores, o que pode ser útil para ações de combate aos ilícitos ambientais. A princípio, as imagens Planet não são gratuitas, porém recentemente a Noruega adquiriu um acervo para todas as áreas tropicais entre 2015-2021 e distribuiu de forma aberta pelo produto *Norway's International Climate and Forest Interactive* (NICFI) (HERMANSEN et al., 2017).

Outra etapa fundamental da pesquisa se desenvolveu através da utilização da inteligência artificial (IA) para auxiliar no mapeamento da degradação florestal. Dentro deste campo, a eficácia do *deep learning* revolucionou as possibilidades de análise de padrões espaciais em dados de observação da Terra (KATTENBORN et al., 2021). No que se refere ao mapeamento da degradação florestal, esta técnica inovadora tem se apresentado muito útil, uma vez que possibilita a identificação de objetos e fenômenos

em imagens de satélite com mais nitidez e clareza, principalmente em imagens de alta resolução. Comparado com outros métodos de *machine learning*, como por exemplo, o Random Forests (BREIMAN, 2001), as Redes Neurais Convolucionais (ou *Convolutional Neural Networks* - CNN) analisam a informação contextual dos pixels das imagens, não apenas o pixel isolado, obtendo um melhor mapeamento dos alvos terrestres. Dentre os principais modelos de CNN, a U-Net (RONNEBERGER et al., 2015) se destaca por direcionado para a segmentação e exibição gráfica, o que colaborou muito para a execução do modelo. Esse tipo de rede foi usado para segmentar com alta resolução espécies de árvores no dossel da Amazônia (WAGNER et al., 2020), mapeamento da degradação florestal na Mata Atlântica (WAGNER et al., 2020) e detecção de desmatamento na Amazônia (MARETTO et al., 2021). No entanto, a U-Net ainda não havia sido diretamente utilizada para detectar processos relacionados à degradação florestal com imagens de alta resolução.

Neste contexto, a Floresta Nacional do Jamari foi selecionada para analisar o processo de degradação e sua detecção através de imagens Planet e métodos de inteligência artificial. Sua vegetação ombrófila densa e aberta cobre aproximadamente 2200 km², dos quais cerca de 960 km² (44%) são destinados para a concessão florestal desde 2008 (DALAGNOL et al., 2019). A exploração seletiva de madeira na região segue as normas e diretrizes do Plano de Manejo da Flona do Jamari (SFB, 2022), sendo responsabilidade das empresas o monitoramento da dinâmica de crescimento e recuperação da floresta por meio de unidades permanentes que fazem parte do Sistema de Inventário Florestal Contínuo (MUNIZ; PINHEIRO, 2019). 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. Essa área também conta com a disponibilidade de dados de campo para as árvores exploradas e dados LIDAR aerotransportados (*Light Detection and Ranging*) antes e depois do corte, os quais já foram explorados anteriormente pelo orientador Dr. Ricardo Dalagnol (DALAGNOL et al., 2019). Com isso, a combinação destes elementos pode proporcionar o desenvolvimento de uma metodologia inovadora para monitoramento de degradação florestal na Amazônia.

A pesquisa em questão está inserida em um projeto maior que possui como objetivo desenvolver um sistema de monitoramento global da degradação florestal para florestas tropicais, articulado pelo Dr. Ricardo Dalagnol, pesquisador da Universidade da Califórnia em Los Angeles (UCLA) e do Jet Propulsion Lab (NASA). A pesquisa também dialoga com um projeto voltado para a predição da degradação florestal a fim de se evitar queimadas e incêndios florestais em colaboração com o CEMADEN e a FAPESP.

1.2 Objetivos

1.2.1 Objetivo geral

Desenvolver, avaliar e validar a precisão de um modelo de *deep learning* capaz de detectar padrões da degradação florestal (corte seletivo legal e ilegal) na Floresta Nacional do Jamari entre 2016 e 2021, utilizando imagens de alta resolução espacial de satélites Planet.

1.2.2 Objetivos específicos

- 1) Estratificar e quantificar a degradação entre corte seletivo e/ou ilegal com base em dados de campo e referência oficial;
- 2) Avaliar padrões espaciais da degradação na Floresta Nacional do Jamari e arredores.

2. DESENVOLVIMENTO

2.1 Revisão de literatura:

2.1.1 Degradação florestal na Amazônia

As florestas brasileiras que compõem a Amazônia são alvos de contínua expansão do uso e exploração da terra através da extração madeireira, desmatamento para uso agropecuário e desenvolvimento urbano (ASNER et al., 2002). Os territórios desmatados nos estados do Pará, Mato Grosso e Rondônia correspondem a maior parte do desmatamento na Amazônia Legal, sendo atividades como a pecuária e agricultura os maiores responsáveis por este processo (SCHNEIDER et al., 2000, citado por

MUNIZ; PINHEIRO, 2019). A mineração, principalmente do ouro (KALAMANDEEN et al., 2020), também impacta severamente no uso e exploração da terra na região amazônica, uma vez que mineradoras possuem interesses econômicos e disputam com comunidades tradicionais locais (agricultoras, coletoras, ribeirinhas e quilombolas) o domínio sobre o território e seus atributos materiais e simbólicos, e principalmente sobre os recursos naturais (WANDERLEY, 2009). A partir da década de 1960, a ocupação da região Norte do Brasil aumentou intensamente as taxas de desmatamento e de uso da terra na Amazônia, o que também alterou completamente o regime de fogo, visto que estes processos estão intimamente conectados (COPERTINO et al., 2019). Dentro desta perspectiva, um processo, que por muitas vezes é subestimado, mas que merece destaque por sua relevância tanto para o ciclo do carbono quanto para o clima, é a degradação florestal.

A degradação se diferencia do corte raso quando não remove toda a cobertura florestal e se associa ao fogo, representando a perda gradual de vegetação (RAPPAPORT et al., 2018). As perturbações na floresta causadas pela degradação podem ser facilitadas pela exploração madeireira, e efeitos de fragmentação e formação de bordas (FEARNSIDE, 2005). Essas perturbações além de causar perda de carbono contribuem para a perda de biodiversidade florestal (FEARNSIDE, 2005). Observa-se uma crescente preocupação em relação às mudanças climáticas e como elas impactam nos processos ecológicos da Amazônia (ARAGÃO et al., 2008). Na Amazônia, a degradação afetará a floresta ainda mais que o desmatamento em longo prazo (MATRICARDI et al., 2020), uma vez que a extração madeireira é frequente ao longo de toda sua extensão e a incidência de queimadas descontroladas aumenta cada vez mais.

A degradação é em grande parte das vezes o fenômeno precursor do desmatamento, que se inicia com a abertura de estradas na floresta (legais e ilegais), permitindo a ocupação e o surgimento de empreendimentos relacionados à indústria madeireira; posteriormente, é comum que ocorra a conversão da floresta em campos de cultivo (principalmente soja e algodão), áreas de agricultura familiar ou mecanizada e pastagens pecuárias, sendo estes processos responsáveis por aproximadamente 80% do desmatamento na Amazônia legal (FERREIRA et al., 2005). O impacto deste fenômeno

pode ser identificado a partir: da perda da capacidade produtiva do solo (erosão, deficiência de nutrientes e compactação); de mudanças no regime hidrológico (conversão em pastagem e inundações irregulares); da perda de biodiversidade; e do aumento da emissão de gases do efeito estufa (FEARNSIDE, 2005). A fragmentação florestal ocasionada pelo desmatamento é responsável por destruir o bloqueio natural de umidade contra o descontrole das queimadas, que agora avançam sobre a vegetação (COPERTINO et al., 2019).

O fogo na Amazônia não ocorre de forma natural devido à alta umidade das florestas, e é utilizado pelos seres humanos para a conversão florestal em áreas agrícolas, no combate de pragas e manejo de áreas agrícolas (DIAZ et al., 2002). Somado a isto, a vegetação amazônica não se recupera rapidamente após as queimadas, por conta da maioria das árvores das florestas primárias deste bioma não possuírem adaptações fisiológicas de resistência (COPERTINO et al., 2019). O fogo é potencializado pela extração de madeira, que promove a abertura do dossel da floresta e alterações microclimáticas, aumentando a suscetibilidade da floresta ao fogo (FEARNSIDE, 2005), ou seja, quanto mais desmatamento, maior o número de focos de calor (SILVÉRIO et al., 2019). Embora a queimada seja uma técnica antiga e tenha seus malefícios conhecidos, sua ocorrência na Amazônia é responsável pelo alto índice de emissão de gases de efeito estufa, promovido por processos como: áreas desmatadas para agricultura e pecuária; incêndios florestais (ocasionado pelo descontrole de uma queimada); e queimada de capoeiras, pastagens, e diferentes tipos de savanas (FEARNSIDE, 2002). Em relação à degradação, o fogo contribui substancialmente para sua expansão, contradizendo a informação que os incêndios florestais só atingem proporções catastróficas em anos de seca extrema (LEMOS; CUNHA, 2021).

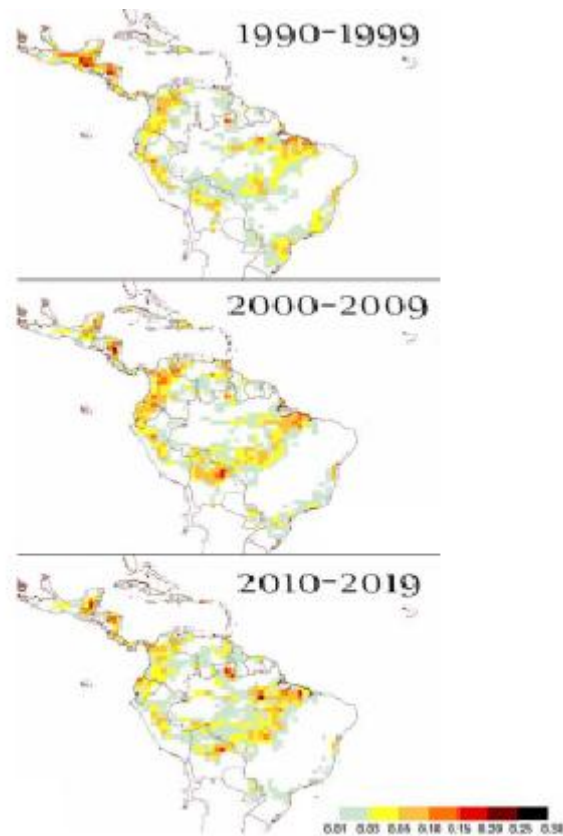
O desmatamento e queimadas afetam diretamente o ciclo hidrológico da Amazônia, por meio de consequências como a redução da evapotranspiração florestal (COPERTINO et al., 2019). A remoção da cobertura florestal e substituição por áreas agrícolas promovem tanto a redução quanto o aumento de chuva em determinadas regiões, sendo a chuva reduzida em maior escala no período menos chuvoso em algumas partes da Amazônia (COHEN et al., 2007). Já as queimadas determinam a quantidade de gases emitidos não somente da parte da biomassa que queima, mas

também da parte que não queima, sendo posteriormente oxidada. Durante a ocorrência de uma queimada, há a liberação de gás carbônico (CO₂), metano (CH₄), monóxido de carbono (CO) e nitroso de oxigênio (N₂O) (FEARNSIDE, 2002).

Um estudo dos pesquisadores do *Climate Policy Initiative/PUC-Rio* (CPI/PUC-Rio) nos revela que a relação da degradação com o desmatamento apresenta forte variação entre categorias fundiárias (GANDOUR et al., 2021), como terras indígenas, Unidades de Conservação, florestas não destinadas e projetos de assentamentos. Nesse sentido, a agricultura de *commodities* em larga escala intensifica os impactos climáticos do desmatamento na Amazônia (MAEDA et al., 2021). Esse estudo mostrou que o desmatamento causado por grandes propriedades rurais com tamanho médio de 374 ha causou maior diminuição na chuva convectiva e maior aumento na temperatura da superfície em relação a pequenas propriedades com tamanho médio de 52 ha (MAEDA et al., 2021). Ademais, é importante destacar a importância das terras indígenas (e unidades de conservação) para proteção ambiental da Amazônia (COSTANTI; NOGUEIRA, 2018), sendo que estas cobriam 21,7% do território da Amazônia Legal em 2010, área correspondente a 98,6% da extensão de terra indígenas do Brasil (RICARDO, 2011).

A degradação florestal foi quantificada por meio de imagens de sensoriamento remoto para a América do Sul mostrando que a principal área afetada é a Amazônia, espalhada pelos países da América do Sul (VANCUTSEM et al., 2021) (Figura 1). O estudo aponta um aumento acentuado nas taxas de desmatamento e degradação (+2,1 milhões de ha/ano entre 2017-2021 em comparação com o período 2005-2014), o que representa um nível próximo ao do início dos anos 2000 e com os maiores aumentos observado na América Latina (48% maior).

Figura 1 - Evolução da área total degradada entre os anos de 1990-2019.



Fonte: Adaptada de Vancutsem et al. (2021).

2.1.2 Monitoramento da degradação florestal por sensoriamento remoto

O processo do desmatamento, seja ele legal ou ilegal, pode ser visualizado facilmente identificado em imagens de satélite (ASNER et al., 2005) através de características bem típicas em sua área de ocorrência: rompimento abrupto da tonalidade verde da vegetação para blocos cinza (áreas desmatadas); e associação a estradas e pátios. No caso da degradação, essa identificação é mais complexa, pelo fato deste processo ocorrer gradualmente e a perda de cobertura vegetal apresentar feições mais discretas. Os focos e padrões da degradação florestal são identificados nestas imagens através de estradas e clareiras próximas (trilhas e clareiras de queda de árvores), “cicatrices” de incêndios e queimadas e pátios de extração madeireira (PINHEIRO et al., 2016) (Figura 2). Sendo assim, o uso de imagens de alta resolução espacial e ferramentas de análise temporal são eficazes durante a etapa de reconhecimento, principalmente quando estes elementos são somados a ferramentas de inteligência artificial.

Figura 2 – Focos e padrões de degradação florestal.



Fonte: O autor (2022).

Com a intensificação do desmatamento e da degradação florestal, surgem iniciativas de mapeamento e monitoramento destes fenômenos através do sensoriamento remoto, tais como: o *JRC Tropical Moist Forest (JRC-TMF)* (VANCUTSEM et al., 2021; produto disponível em: <https://forobs.jrc.ec.europa.eu/TMF>); o *DETER-B (Sistema de Detecção do Desmatamento em Tempo Real)* (DINIZ et al., 2015; produto disponível em: <http://terrabrasilis.dpi.inpe.br/app/map/alerts?hl=pt-br>); o *RADD (Radar for Detecting Deforestation)* (REICHE et al., 2021; produto disponível em

<https://nrtwur.users.earthengine.app/view/raddalert>); e os produtos do laboratório GLAD (*Global Land Analysis and Discovery*) da Universidade de Maryland, EUA, *Global Forest Change* (HANSEN et al., 2013; disponível em: <https://glad.earthengine.app/view/global-forest-change>), GLAD-L (HANSEN et al., 2016; disponível em: <https://www.globalforestwatch.org/map>) e GLAD-S2 (PICKENS et al., 2020; disponível: <https://www.globalforestwatch.org/map>).

No entanto, os sensores de alta resolução possuem limitação na disponibilidade de dados e imagens, assim como as técnicas utilizadas não têm grande poder de generalização/predição para novas regiões e/ou grandes áreas. Este obstáculo possui uma possível solução: a combinação de imagens Planet com técnicas de *deep learning*.

As imagens utilizadas neste projeto foram geradas pela constelação *PlanetScope* de satélites tipo DOVE (*Digital Orbiting Voice Encoder*) da missão Planet, operação que fornece a maior capacidade atual de monitoramento terrestre remotamente e possui objetivos direcionados para a reversão dos impactos humanos em florestas tropicais, combate às mudanças climáticas e desenvolvimento sustentável (*The European Space Agency*). A câmera PlanetScope em cada satélite DOVE obtêm dados com 3m de resolução espacial e coleta dados em quatro bandas: vermelho, verde, azul e infravermelho próximo. O imageamento da superfície terrestre ocorre com taxa de revisita quase diária (~1-3 dias) em áreas tropicais, o que fornece cobertura global através de imagens visíveis ao infravermelho próximo e já com correção atmosférica (ROY et al., 2021). Recentemente, imagens Planet, adquiridas desde Dezembro de 2015, foram disponibilizadas gratuitamente para os trópicos por meio do programa NICFI (*Norway's International Climate and Forest Initiative*), ampliando as possibilidades para o mapeamento da degradação florestal. O produto Planet NICFI apresenta resolução espacial de 4.77 m e possibilita a visualização dos efeitos de degradação na floresta com maior nitidez e frequência que missões anteriores, principalmente pela sutileza destes e intersecção com o desmatamento. Traz dados bi- anuais de 2016 até 2020, e mensais a partir de setembro de 2020 até os dias atuais. Após a análise de padrões de degradação, utilizou-se de dados de campo previamente explorados pelo orientador Dr. Ricardo Dalagnol (DALAGNOL et al., 2019). Sendo

assim, a combinação destes elementos pode proporcionar o surgimento de uma metodologia inovadora para monitoramento de degradação florestal na Amazônia.

Dados aerotransportados de alta resolução LiDAR (*Light Detection and Ranging*) também são muito relevantes para um delineamento mais preciso da degradação e quantificação de perda de carbono, em nível de árvores individuais, uma vez que estes dados resultam num conjunto de informações relevantes sobre a estrutura horizontal e vertical da superfície analisada (ARAUJO et al., 2013). Um sensor aerotransportado equipado com dispositivo LiDAR identifica as principais informações presentes na área de estudo, segmentando pontos e estruturas através de múltiplos feixes (HABERMANN, 2016). Já houveram iniciativas bem sucedidas que utilizaram LiDAR na detecção de fenômenos como: análise temporal de efeitos da exploração madeireira (PINAGÉ et al., 2015); alterações pós fogo na biomassa florestal da Amazônia (SATO, 2016). E até mesmo casos mais específicos como a quantificação da perda do dossel de árvores e recuperação de lacunas em florestas tropicais sob exploração madeireira de baixa intensidade (DALAGNOL et al., 2019).

No entanto, produtos LiDAR possuem sua difusão em larga escala dificultada pela complexidade de obtenção destes dados. Sua produção requer o uso de sensores de alto valor financeiro no mercado atual e a disponibilidade de voos sobre a área de estudo. Locks e Matricardi (2019) afirmam que estes produtos ainda necessitam de uma análise mais detalhada quando aplicados para o monitoramento de impactos em florestas tropicais, como é o caso da Amazônia. Nesse sentido, algumas possibilidades a se explorar seriam o uso do LiDAR de forma combinada com mapas de alta resolução da degradação gerado por satélite, para estimativas precisas da perda de biomassa e carbono.

2.1.3 Detecção de alvos com imagens de sensoriamento remoto através do *deep learning* e redes neurais convolucionais

Outra etapa fundamental da pesquisa se desenvolveu através da utilização da inteligência artificial (IA) para auxiliar no mapeamento da degradação florestal. A IA se caracteriza enquanto uma ciência que engloba a cibernética e a computação numa iniciativa de produzir um comportamento inteligente semelhante ao humano

(TEIXEIRA, 2019). Este ramo da ciência é comumente associado ao sensoriamento remoto, com o objetivo de automatizar o fluxo de trabalho e auxiliar nas mais diversas abordagens analíticas geoespaciais.

Dentro da IA, o *machine learning* está diretamente ligado com a estatística aplicada, com objetivo de construir modelos computacionais baseados no reconhecimento de padrões ao invés de conjuntos explícitos de regras (DRAMSCH, 2020). O avanço das geociências oferece enorme potencial para o desenvolvimento do *machine learning*, representando uma revolução significativa para a solução de problemas e entendimento de fenômenos das geociências de grande importância social (KARPATNE et al., 2018). Algumas técnicas relevantes para aplicação de *machine learning* em sensoriamento remoto são Support Vector Machine (SVM) (LORENA; CARVALHO, 2007) e Random Forests (RF) (BREIMAN, 2001). No entanto, métodos de *deep learning* revolucionaram o impacto do machine learning em diversas aplicações modernas, como por exemplo, visão computacional, fala e reconhecimento e tradução de idiomas (KARPATNE et al., 2018). Modelos de *deep learning* se apresentam como um dos mais modernos e eficazes relacionados às geociências.


Como subcampo do *machine learning*, o *deep learning* permite aplicações que variam da percepção da máquina ao processamento de linguagem natural, de acordo com representações de dados que enfatizam a comunicação entre os canais de processamento (CHOLLET; ALLAIRE, 2017). Uma vantagem do *deep learning* se comparado ao *machine learning* está relacionada à sucessão de camadas. Um modelo de *deep learning* geralmente envolve centenas de camadas sucessivas de representação (*layers*) - todos são “aprendidos” automaticamente com a exposição aos dados de treinamento (CHOLLET; ALLAIRE, 2017). Essas camadas podem ser combinadas em inúmeras configurações de entrada (*input*) e saída (*output*) (DRAMSCH, 2020). Com isso, o funcionamento de um modelo de *deep learning* prevê a automatização do fluxo de processamento de dados e informações através da simulação de um comportamento humano de análise.

Desde meados dos anos 2000, diversos modelos e arquiteturas de *deep learning* ressurgiram junto com redes neurais (MANIAR et al., 2018). A década de 2010 representou o renascimento do *deep learning* e mais especificamente das redes neurais

convolucionais (CNN - do inglês *convolutional neural network*) (DRAMSCH, 2020). O modelo de *deep learning* utilizado no projeto foi processado a partir de uma rede neural convolucional, proveniente do processo conhecido como convolução.

A convolução consiste num conjunto de operações matemáticas lineares entre matrizes (ALBAWI et al., 2017). Na convolução, uma janela (matriz ou *kernel*) de tamanho w desliza sobre a imagem realizando a multiplicação de valores entre a imagem e a janela (Figura 3). Os valores das janelas da convolução em cada camada são alterados e treinados durante o processo de treinamento. O papel de uma rede neural convolucional nos modelos de *deep learning* é de extrair atributos espaciais das imagens, como bordas e feições lineares, que caracterizam os alvos da superfície (CHAUHAN et al., 2018). Dessa forma, o modelo aprende a selecionar atributos que melhor auxiliam na aplicação que estiver se desenvolvendo, por exemplo, a segmentação de imagem.

Figura 3 - Exemplo de uma rede convolucional de três camadas.



A imagem de entrada (amarela) passa pela convolução com vários filtros ou matrizes de kernel (roxo).


Fonte: Adaptado de Dramsch (2020).

Comparado a modelos de *machine learning* tradicionais no sensoriamento remoto, os métodos de *deep learning* tem como vantagens como: treinamento *end-to-*

end que minimiza as etapas de pré-processamento para extração de atributos por parte do modelo (LI, 2018) e melhor generalização para novas combinações de valores e características assimilados além daquelas vistas durante o treinamento (LECUN et al., 2015).

Dentre os modelos de *deep learning* existentes, um modelo tem se destacado para aplicações em monitoramento florestal, a U-Net (RONNEBERGER et al., 2015). A arquitetura da U-Net realiza a classificação individual por pixel, analisando a probabilidade de cada pixel pertencer a uma classe específica (WAGNER et al., 2019). A primeira parte da U-Net - da parte inicial até a metade - pode ser denominada como *encoder* ou *downsampling*, onde são extraídas informações das feições em múltiplas escalas. Na sequência, há um *decoder*, que retorna tais informações à escala inicial em nível de pixel na resolução original da imagem (Figura 4). Em cada nível, têm-se duas camadas de convolução com kernel de tamanho 3x3 e um número de atributos que aumenta de acordo com a profundidade da rede até o centro. Esses atributos contém a informação das feições extraídas em cada nível. Posteriormente, é realizado um processo de *pooling* com operador máximo (*max pooling*) que serve para extrair a informação mais relevante de cada filtro e ao mesmo tempo reduzir a dimensão das representações. Após chegar ao centro do modelo, inicia-se o processo de *decoder* ou *upsampling*. O *output* de cada camada é reamostrado numa escala de 2x2, dobrando sua dimensão espacial, e combinado com as representações de mesma dimensão advinda do *downsampling*, num processo que se chama *skip connection* (*copy and crop* na Figura 4). Dessa forma, em cada nível acima as representações possuem uma dimensão mais próxima da dimensão original do *input*, no entanto é esperado que mantenham a informação das feições que foram extraídas. Ao final da rede, utiliza-se uma camada de convolução 1x1 para produzir um *output* final das máscaras de interesse.


Figura 4 – Arquitetura da rede U-net



Fonte: Adaptado de Ronneberger et al. (2015).

Alguns componentes do modelo correspondem à função de ativação, que se encontra logo após cada camada convolucional e serve para normalizar os valores do *output* para valores esperados de acordo com a função. Na U-Net e outras redes de *deep learning*, comumente usa-se a função *rectified linear unit* (ReLU) (HE et al. 2018) (Figura 5) que remove os valores negativos.

Figura 5 - Exemplo de representação da função de ativação ReLU.



Somente os valores positivos são retornados.

Fonte: o autor.

As imagens de *input* e seus mapas de segmentação correspondentes são usados para treinar a rede com o algoritmo *stochastic gradient descent* (SGD) (KIEFER; WOLFOWITZ, 1952) e o aprendizado por retropropagação (*backpropagation*) (RUMELHART et al., 1986). O objetivo desse algoritmo é encontrar o melhor conjunto de pesos para resolver o problema que está sendo modelado. O treinamento é iniciado através da atribuição de valores iniciais para os parâmetros, depois realiza-se uma época - o modelo trabalha com todas as imagens e obtém-se os *outputs*, e posteriormente, o erro em relação ao valor esperado é calculado. Esse erro é redistribuído para as camadas e aplicado a uma taxa de aprendizado, para que a mudança nos parâmetros seja pequena a cada interação. Os valores iniciais dos parâmetros podem ser aleatórios ou baseado em uma distribuição Gaussiana, de modo que a rede tenha aproximadamente variação unitária com um desvio padrão desvio de $\sqrt{2}=\sqrt{N}$, onde N corresponde ao número de nós conectados a um neurônio (HE et al., 2015, citado por RONNEBERGER et al., 2015). A atualização dos pesos segue uma taxa de aprendizado que geralmente é próxima de 0,001. As metodologias de treinamento mais recentes têm utilizado uma apresentação de amostras de imagens em lotes (ou *batches*) de tamanho variável ao invés de todas as imagens de uma só vez.

A função de perda (*loss function*) de uma rede neural é responsável por calcular a diferença (ou “distância”) de valores entre os resultados e previsões da rede e o valor esperado, a fim de medir a eficácia do modelo (CHOLLET; ALLAIRE, 2017).

Técnicas de *data augmentation* possuem a finalidade de expandir amostras de imagem de treinamento insuficientes para a classificação de imagens (SHIJIE et al., 2017). Recentemente, houve um aumento extensivo no uso de dados genéricos para melhorar o desempenho das CNNs (TAYLOR; NITSCHKE, 2017).

Estudos recentes que combinam o *deep learning* com a CNN U-Net têm realizado mapeamentos antes não imagináveis e imprecisos, como mapeamento da distribuição espacial de palmeiras na Amazônia (WAGNER et al., 2020), mapeamento de espécies como a embaúba na Mata Atlântica a qual é uma indicadora de degradação

e do histórico da regeneração (WAGNER et al., 2020), e mapeamento dos tipos de floresta e perturbações na Mata Atlântica (WAGNER et al., 2019). Sendo assim, a expectativa é muito alta no que se refere à perspectiva do uso de *deep learning* para mapeamento da degradação florestal a partir de imagens de alta resolução.

2.1.4 Concessão florestal e degradação na Floresta Nacional do Jamari

A concessão florestal surge como uma alternativa pública e estratégica para o monitoramento florestal, inserida no ordenamento jurídico brasileiro por meio da Lei nº 11.284 de 2006 (OLIVEIRA, 2010). Esta lei é caracterizada pelo Manejo Florestal Sustentável, que garante à iniciativa privada o direito de exploração da floresta segundo os princípios de gestão de florestas públicas (CHULES, 2018). No processo de concessão florestal, há a autorização de direitos diversos, principalmente comerciais, através de licitações por parte do poder público ao particular para exploração dos recursos naturais da área delimitada (OLIVEIRA, 2010). A concessão florestal tem como objetivo coibir a exploração ilegal e a grilagem², na esperança de preservar as florestas (MARTINS; MASCARENHAS, 2018). Até 2020 no Brasil, existiam 18 Unidades de Manejo Florestal (UMF) distribuídas por uma área total de 1,050 milhão ha em seis florestas públicas nacionais.

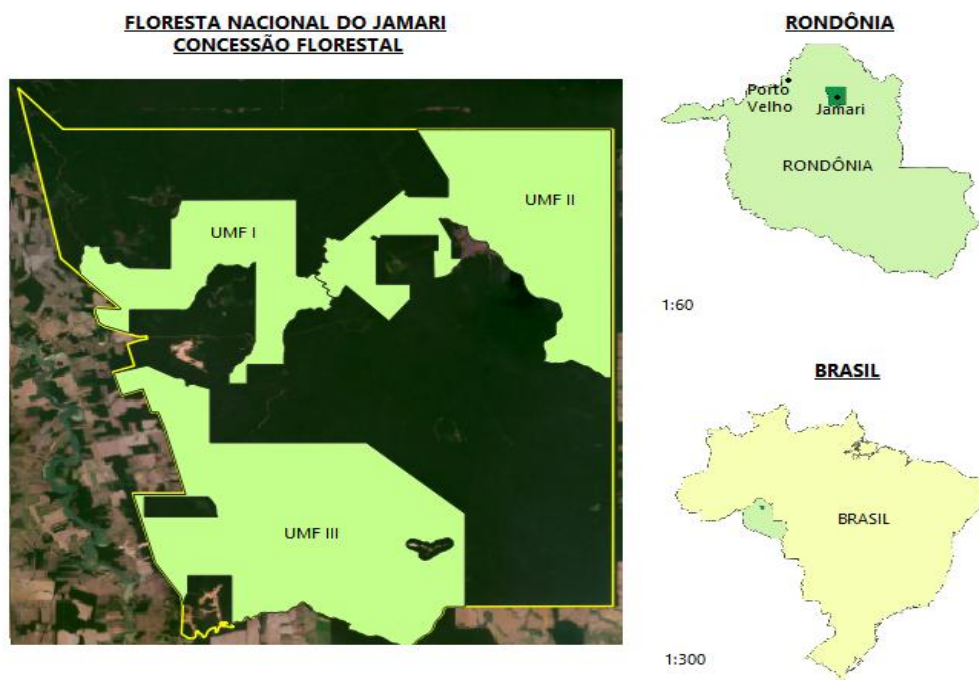
A concessão é regida por um Plano de Manejo Florestal (PMF) e ocorre na prática pelo parcelamento da floresta em áreas de manejo, onde a concessionária se torna responsável pelo gerenciamento da sua parcela da área florestal, obtendo sua receita através da produção madeireira (TILLMANN et al., 2016). A partir deste documento, ocorre o agendamento das UMFs a serem extraídas ao longo dos anos (GOMIDE, 2013). Em cada UMF, há a divisão do território em Unidades de Produção Anual (UPA), e por sua vez a execução de um Plano Operacional Anual (POA) que divide a UPA em Unidades de Trabalho (UT). A seleção de árvores para o corte dentro de cada UPA é baseada em critérios como: função do mercado; diâmetro ou circunferência mínima de corte (DMC ou CMC); qualidade de fuste; e distribuição espacial das árvores (SFB, 2022). Ainda na seleção, há o corte de cipós das árvores, com objetivo de facilitar a derrubada de árvores, diminuir os danos às árvores

²Processo de transformação de uma porção de terra legalmente adquirida em porções maiores ilegalmente incorporadas a um patrimônio particular, por meio do apossamento de terras alheias mediante falsas escrituras de propriedade (MOTTA, 2001).

remanescentes e aumentar a segurança das equipes operacionais durante a exploração (SFB, 2022).

A Floresta Nacional do Jamari foi a primeira Unidade de Conservação brasileira a ser submetida ao regime de concessão florestal (SOUZA; SCCOTI, 2020). Dos seus 2200 km², aproximadamente 960 km² (44%) foram destinados para extração seletiva desde 2008 (DALAGNOL et al., 2019). De acordo com a base de dados do Serviço Florestal Brasileiro (SFB, 2022), a divisão inicial da Flona do Jamari foi feita da seguinte forma (Figura 6): a UMF I possui 17,5 mil hectares e é de responsabilidade da Madeflona Industrial Madeireira; a UMF II possui 32,9 mil hectares e é de responsabilidade da Sakura Indústria e Comércio de Madeiras; e a UMF III possui 46 mil hectares, sendo administrada pela Amata. Desta divisão, ocorreram diversas alterações devido imbróglis judiciais e falta de cumprimento de obrigações por partes de algumas concessionárias, o que mudou a disposição e divisão inicial das UMFs, como por o exemplo o contrato da empresa Sakura, rescindido em 2012 (CHULES, 2018).

Figura 6 – Mapa das UMFs da Flona do Jamari.



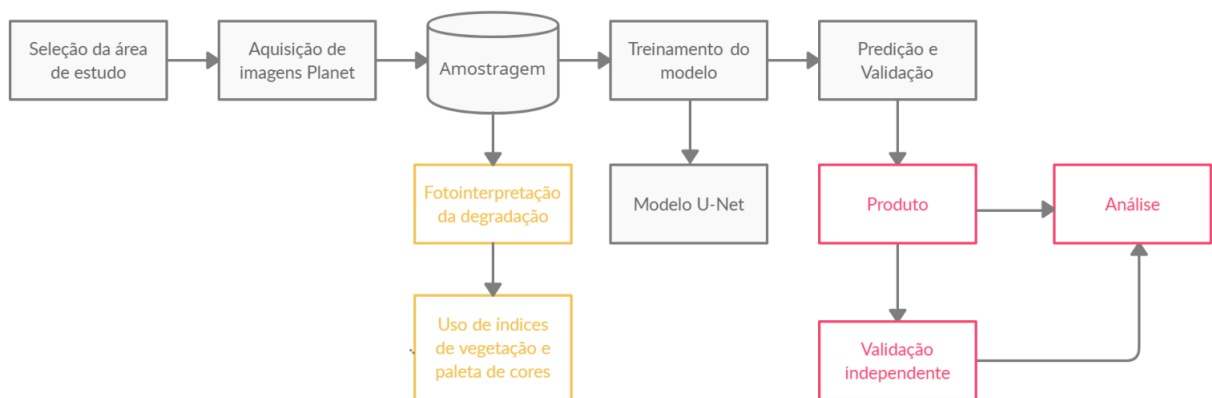
Fonte: o autor.

O plano de manejo da Floresta Nacional do Jamari conta com cinco volumes que tratam das informações gerais sobre a floresta, planejamento, sumário executivo, encartes cartográficos e anexos. O tempo de regeneração necessário para novas extrações é de 25 a 30 anos. Durante o inventário pré-exploratório, algumas atividades essenciais são realizadas: seleção de todas as árvores da floresta iguais ou acima de 35 cm de diâmetro; identificação botânica; e estimativa da altura de cada árvore; e geolocalização das árvores.

2.2 Materiais e métodos

A pesquisa foi estruturada a partir das seguintes etapas: seleção da Floresta Nacional do Jamari como área de estudo; aquisição de imagens Planet que cobrissem a Flona do Jamari e concomitância com a informação de campo – entre 2016 e 2021; amostragem de padrões da degradação nas imagens no software QuantumGIS (QGIS); treinamento e aplicação do modelo em toda a área de estudo; geração de um produto que identificou o corte seletivo legal e ilegal na Flona do Jamari; validação das informações junto à referência oficial; e análise estatística da acurácia do mapeamento (Figura 7).

Figura 7 - Fluxograma com as etapas do projeto.




Fonte: o autor.

2.2.1 Seleção da 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

e Itapoã do Oeste (Figura 8). A floresta cobre 2.200 km² de florestas abertas ombrófilas de planície de terra firme, com espécies de árvores de alto valor comercial (DALAGNOL et al., 2019). De acordo com a classificação de Köppen Geiger, o clima é de tipo Am, o que garante secas bem definidas e baixa amplitude térmica anual (ALVARES et al., 2014, citado por FAGUNDES et al., 2020). Desde a década de 1980 a área sofre pressão da mineração, agropecuária e criação de assentamentos da reforma agrária que modificaram paisagem (BASTOS et al., 2017).

Figura 8 – Localização da Floresta Nacional do Jamari e seu limite.



Fonte: o autor.

2.2.2 Aquisição de imagens Planet

Durante o desenvolvimento da pesquisa, as imagens e informações foram viabilizadas através do programa NICFI, que disponibilizou mosaicos de imagens da missão Planet de alta resolução com o objetivo de ajudar a reverter a perda de florestas tropicais, combater mudanças climáticas, incentivar a conservação da biodiversidade e o desenvolvimento sustentável. O uso de imagens de toda a região tropical dos anos de 2017 até 2022 permitiu que analisássemos temporalmente e espacialmente nossa área de

estudo dentro da Amazônia. As imagens são provenientes das bandas do azul (455 – 515 nm), verde, (500 – 590 nm) vermelho (590 – 670 nm) e infravermelho próximo (780 – 860 nm), com resolução espacial de 4.7 metros. O mosaico Planet NICFI é subdividido em *quads* (*pedaços de imagem*) com 20x20 km de extensão, equivalente a 4096x4096 pixels. Os resultados foram avaliados visualmente e numericamente, comparando com as zonas de manejo outorgadas para a área e através da geolocalização das árvores cortadas em cada ano.

Para fotointerpretação, os mosaicos foram visualizados através do *plugin* Planet Explorer disponível na versão 3.16.11 (Hannover) do software QGIS, no qual são disponibilizadas prévias, *downloads* e *streamings* de imageamento diário. Na seção “*Basemaps*” do *plugin* foram selecionadas imagens de Agosto de 2021 na seção “*PS Tropical Normalized Analytic Monthly Monitoring*” (esses dados correspondem a uma composição de imagens do mês de Agosto). Para treinamento e predição do modelo, as imagens foram adquiridas através da API da Planet em programação R, baixando automaticamente as imagens.

2.2.3 Índices de vegetação

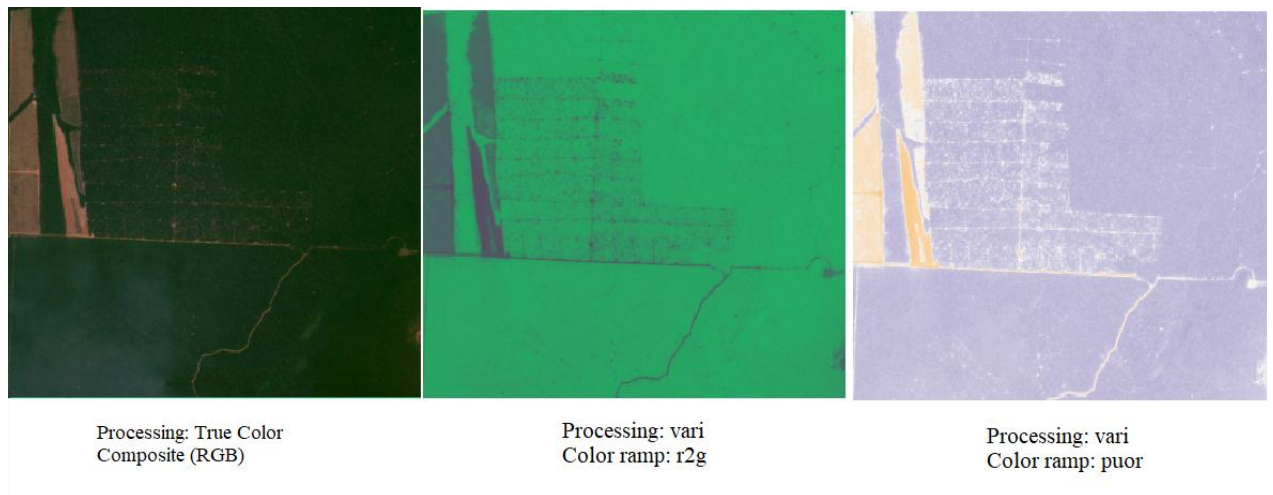
O uso de índices de vegetação e paletas de cores foi essencial para a fotointerpretação, uma vez que auxiliaram no processo de identificação visual. Dentre os índices de vegetação existentes no produto NICFI pelo *plugin* do QGIS, utilizou-se principalmente o índice VARI (Índice Resistente à Atmosfera 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). Duas paletas de cores foram exploradas para melhor visualização da degradação, sendo elas a *r2g* e a *puor* (Figura 9).

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

Onde VARI = Índice de Vegetação Resistente à Atmosfera na Região do Visível; G consiste na banda do verde; R consiste na banda do vermelho; e B consiste na banda do azul.

Fonte: Gitelson et al., 2002

Figura 9 - Representação da degradação florestal por extração de madeira através de (1) composição cor verdadeira; e índice VARI com paletas de cores (2) r2g, e (3) puor.




Fonte: o autor.

Nota-se na figura 9 que o índice VARI mostra maior contraste entre a floresta degradada (verde com linhas e pontos azuis) e não degradada (verde) do que a composição em cor verdadeira (*default*).

Devido ao baixo número de ocorrências de degradação dentro da área de estudo para treinamento do modelo, a coleta de amostras de corte seletivo foi realizada em áreas da Jamari, algumas áreas do Acre e principalmente do Mato Grosso, justificado pelo maior número de áreas degradadas nessas regiões. Foram criados 6480 polígonos na camada de presença de degradação e 1774 na camada de ausência, distribuídos ao longo de 197 *quads* (Figura 10). As amostras de ausência foram distribuídas em locais com características de floresta e ambientes bem variados, mas sem ausência de degradação, de modo a ajudar no treinamento do modelo e entendimento desses padrões.

Figura 10 - Polígonos de presença de corte seletivo e quads Planet



Fonte: o autor.

2.2.4 Treinamento do modelo

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 modelo teve como objetivo realizar a predição de áreas degradadas a partir do treinamento e contato do algoritmo com padrões espaciais de degradação florestal. O *input* do modelo são pequenas imagens chamadas de patches (128 x 128 pixels) contendo as imagens Planet (bandas R, G, B, NIR) e a máscara de degradação previamente delineada. O recorte dos *quads* em patches foi realizado através de código em programação R. Esses patches foram utilizados como *input* do modelo para extrair as máscaras de degradação como *output*. O modelo foi treinado com o algoritmo *standard stochastic gradient* (KIEFER; WOLFOWITZ, 1952).

2.2.5 Banco de dados das concessões florestais

Com o objetivo de elaborar um banco de dados acerca da Floresta Nacional do Jamari, foram compilados dados sobre as concessões florestais de todo país. Foram levantados todos dados e informações contidos na página das concessões no site do Serviço Florestal Brasileiro (SFB), assim como planilhas de dados fornecidas por profissionais competentes.

Todas as informações levantadas serviram para criação de um mapa de corte seletivo de referência oficial, com o objetivo de corroborar e validar as informações geradas pelo produto do modelo.

2.2.6 Métricas estatísticas

A matriz de confusão oferece uma medida efetiva do modelo de classificação, ao representar o número de classificações corretas *versus* as classificações preditas para cada classe (MONARD; BARANAUSKAS, 2003). Com isso, pode-se estabelecer o primeiro parâmetro de avaliação da precisão do classificador: exatidão ou precisão global; o seu valor é calculado através do número de classificações corretas pelo número total de amostras utilizadas (WATZLAWICK et al., 2003) (Equação 2):

$$EG = \left(\frac{CC}{AU} \right) * 100 \quad (2)$$

EG = Exatidão Global

CC = número total de *pixels* corretamente classificados

AU = número total de *pixels*

Em suma, a matriz de confusão é uma forma de representação da qualidade obtida de uma classificação digital de imagem, expressa por meio da correlação de informações dos dados de referência (compreendido como verdadeiro) com os dados classificados (PRINA; TRENTIN, 2015).

Os métodos de correlação estatística representam uma importante ferramenta para diversas áreas do conhecimento, com a função de medir e identificar o comportamento de uma variável em relação à outra. Em sistemas de engenharia, por exemplo, uma análise de confiabilidade é responsável por avaliar a probabilidade de não

haver falha durante a sua vida útil, atendendo aos objetivos para os quais o sistema foi projetado (LIRA; NETO, 2006).

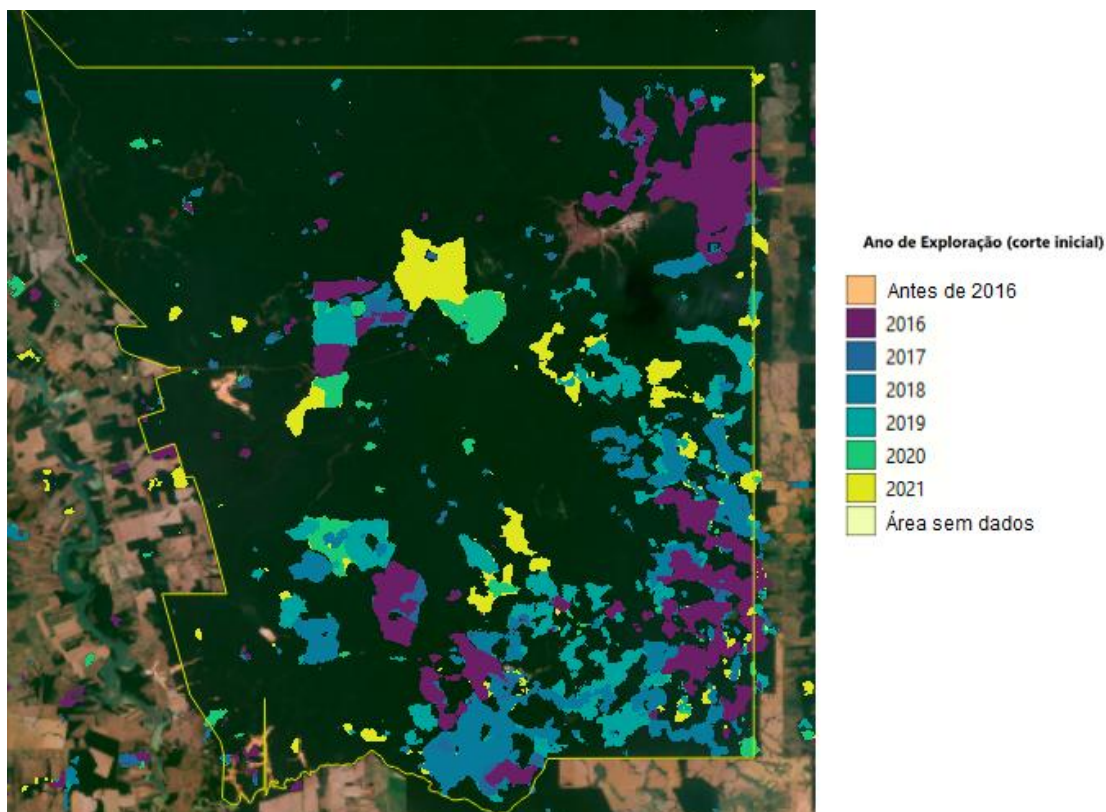
3. CONCLUSÃO

3.1 Resultados

3.1.1 Mapeamento do corte seletivo

O modelo gerou um mapa de corte seletivo para a Floresta Nacional do Jamari durante o período de 2016 a 2021 (Figura 11). 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.

Figura 11 – Produto do modelo



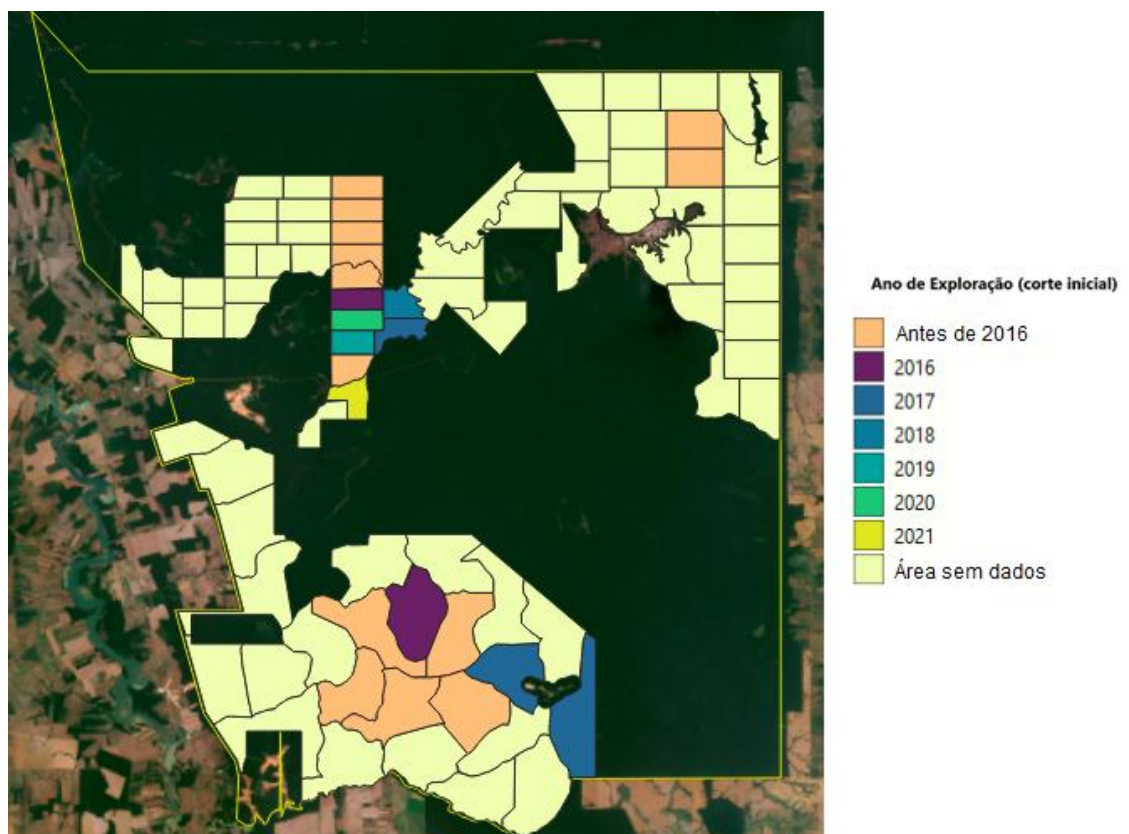
Fonte: o autor.

O padrão de corte seletivo nas UPAs com referência e informações fornecidas pelo SFB se revela nas imagens através de pequenas estradas derivadas de uma estrada principal sentido mata adentro, pequenas clareiras e pátios de exploração.

3.1.2 Comparação visual do mapeamento

A validação da detecção do modelo foi feita através da comparação do produto gerado com o banco de dados das concessões descrito na metodologia. Por meio da compilação de informações do SFB, foi possível a criação de uma imagem (Figura 12) que fosse capaz de confirmar a presença de corte seletivo nas áreas detectadas pelo modelo.

Figura 12 – Compilação dos dados do SFB em forma de mapa de UPAs na Flona do Jamari.



Fonte: o autor.


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.

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. Nessa situação, UPAs como a I-01, I-02, I-03, I-04, I-05, II-01 e II-02, que têm data de corte entre 2010-2014, não foram detectadas no resultado final, uma vez que pelo tempo decorrido, a vegetação foi capaz de se regenerar. No entanto, o SFB possuía informações sobre a data de corte nestas áreas, sendo incluídas na figura final.

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 13). 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.

Figura 13 - Produto do modelo e UPAs nas quais o modelo identificou presença de corte seletivo.



Fonte: o autor

O modelo também detectou áreas de corte seletivo dentro do perímetro de UPAs, porém sem a informação de corte. Essas áreas apresentaram padrões de corte seletivos semelhantes ao de UPAs com referência. Esses padrões consistiram na ocorrência de trilhas lineares, estabelecimento de pátios para estocagem de madeira espaçados na área, e abertura de clareiras no dossel da floresta.

O modelo detectou áreas de corte seletivo fora do perímetros 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.

3.1.4 Avaliação estatística da acurácia do mapeamento

A partir da matriz de confusão (Tabela 1), 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” para os valores 2016 até 2021 da predição. Uma parte deles ocorre por conta de inconsistências na referência do SFB.

Tabela 1 - Matriz de Confusão

		Referência						
		0	2016	2017	2018	2019	2020	2021
Pre di ç ã o	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

Fonte: o autor.

3.1.5 Análise estatística de padrões de degradação na região de estudo

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 13,54% da área total da Flona.

3.2 Discussão dos resultados

Os resultados da pesquisa desenvolvida entre os anos de 2021-2022 estão relacionados com a criação de um modelo preliminar capaz de detectar padrões de corte seletivo e abertura de estradas. Este modelo ainda apresenta divergências nas métricas de avaliação estatísticas, mas é bastante promissor e com a validação correta, alcançará alto índice de confiabilidade.

O potencial da pesquisa é bastante relevante. Acredita-se que o modelo é eficaz e possui um diferencial dos tradicionais anteriormente citados, o uso de imagens de alta resolução. Com a validação por meio de uma base de dados confiável, a porcentagem de acerto do modelo aumentará, conferindo mais precisão e eficácia para o mesmo. A ideia é avançar na quantificação da intensidade do logging com LiDAR e dados de campo já compilados, para que seja possível integrar a avaliação da perda de carbono no modelo.

No entanto, 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. Esta etapa já foi iniciada e houve contato com um representante oficial do SFB, no entanto é um processo lento e burocrático, que não depende exclusivamente da equipe responsável pelo projeto.

A divergência dos resultados preliminares do modelo representam um problema para a validação do modelo e cálculo de métricas estatísticas, uma vez que causa falso positivos e gera resultados que não podem ser comprovados por órgãos oficiais.

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.

Os dados aqui gerados serão compartilhados com a coordenação de monitoramento por satélite do Serviço Florestal Brasileiro para colaborar no monitoramento da concessão florestal na Jamari, e discutido possibilidades de aplicação da metodologia para continuar esse monitoramento.

Os resultados do estudo já foram apresentados como pôster no evento AmeriGEO Week 2022, será submetido também para o GEOINFO, e até o fim de 2022 espera-se finalizar um artigo para submissão em revista científica.

4. REFERÊNCIAS BIBLIOGRÁFICAS

ALBAWI, S.; MOHAMMED, T. A.; AL-ZAWI, S. Understanding of a convolutional neural network. **International Conference on Engineering and Technology (ICET)**. **Anais...**Antalya: IEEE, 2017.

ALVARES, C; STAPE, J. L; SENTELHAS, P. C; GONÇALVES, J. L. d. M.; SPAROVEK, G.. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711-728, 2013.

ÂNGELO, H.; PEREIRA DE SÁ, S. P. O Desflorestamento na Amazônia Brasileira. **Ciência Florestal**, Santa Maria, v. 17, n. 3, p. 217-227, 2007.

ARAGÃO, L.E. O.C; MALHI, Y.; BARBIER, N.; LIMA, A.; SHIMABUKURO, Y.; ANDERSON, L.; SAATCHI, S.. Interactions between rainfall, deforestation and fires during recent years in the Brazilian Amazonia. **Philosophical Transactions Of The Royal Society B: Biological Sciences**, v. 363, n. 1498, p. 1779-1785, 2008.

ASNER, G. P.; KNAPP, D. E.; BROADBENT, E. N.; OLIVEIRA, P. J. C.; KELLER, M.; SILVA, J. N.. Selective Logging in the Brazilian Amazon. **Science**, v. 310, n. 5747, p. 480-482, 2005.

ASNER, G. P; KELLER, M.; PEREIRA, R.; ZWEEDE, J. C. Remote sensing of selective logging in Amazonia Assessing limitations based on detailed field observations, Landsat ETM+, and textural analysis. **Remote Sensing Of Environment**, v. 80, n. 3, p. 483-496, 2002.

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, EUR 30727 EN, **Publications Office of the European Union**, Luxembourg, 2021.

BREIMAN, L.. Random Forests. **Machine Learning**, v. 45, p. 5–32, 2001.

BUNN, A.; KORPELA, M. Crossdating in dplR. 2014.

CHAUHAN, R.; GHANSHALA, K. K.; JOSHI, R. C. Convolutional Neural Network (CNN) for Image Detection and Recognition. **First International Conference on Secure Cyber Computing and Communication (ICSCCC)**. Anais...Jalandhar, India: IEEE, p. 278- 282, 2018.

CHOLLET, F.; ALLAIRE, J. J. Deep Learning With R. Manning, 2018.

CHULES, E. L. Floresta Nacional do Jamari: percepções e expectativas dos atores sobre a concessão florestal. Dissertação (Mestrado - Programa de Pós-Graduação em Desenvolvimento Sustentável). Universidade de Brasília, 2018.

COHEN, J. C. P.; BELTRÃO, J. D. C.; GANDU, A. W.; SILVA, R. R. D. Influência do Desmatamento Sobre o Ciclo Hidrológico na Amazônia. **Cienc. Cult.**, São Paulo , v. 59, n. 3, p. 36-39, 2007.

COPERTINO, M.; PIEDADE, M. T. F.; VIEIRA, I. C. G.; BUSTAMANTE, M. Desmatamento, fogo e clima estão intimamente conectados na Amazônia. **Ciência e Cultura**, v. 71, n. 4, p. 04–05, 2019.

COSTANTI, E. U.; NOGUEIRA, J. M. Conservação, Gestão Ambiental e Produtos da Floresta em Terras Indígenas: do extrativismo predatório aos produtos da sociobiodiversidade. **56 Congresso Sociedade Brasileira de Economia, Administração e Sociologia Rural**. UNICAMP, 2018.

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.

DECAËNS, T. et al. Biodiversity loss along a gradient of deforestation in Amazonian agricultural landscapes. **Conservation Biology**, v. 32, n. 6, p. 1380-1391, 2018.

DIAZ, M. D. C. V.; NEPSTAD, D.; MENDONÇA, M. J. C.; MOTTA, R. S. D.; ALENCAR, A.; GOMES, J. C.; ORTIZ, R. A. O Preço Oculto do Fogo na Amazônia: os custos econômicos associados às queimadas e incêndios florestais. Relatório do Instituto de Pesquisa Ambiental da Amazônia (IPAM) em colaboração com o Instituto de Pesquisa Econômica Aplicada (IPEA) e o Centro de Pesquisa Woods Hole (WHRC), 2002.

DINIZ, C. G.; SOUZA, A. A. d. A.; SANTOS, D. C.; DIAS, M. C.; LUZ, N. C. d.; MORAES, D. R. V. d.; MAIA, J. S. A.; GOMES, A. R.; NARVAES, I. d. S.; VALERIANO, D. M.; MAURANO, L. E. P.; ADAMI, M.. DETER-B: the new amazon near real-time deforestation detection system. **Ieee Journal Of Selected Topics In Applied Earth Observations And Remote Sensing**, v. 8, n. 7, p. 3619-3628, 2015.

DRAMSCH, J. S. 70 years of machine learning in geoscience in review. **Machine Learning In Geosciences**, p. 1-55, 2020.

FAGUNDES, S. T. S.; SCCOTI, M. S. V.; LIMA, A. C.R.; BRITO JUNIOR, J. F.; BIAZATTI, S. C.. Monitoramento da floresta a curto prazo em área de concessão

florestal na Amazônia Ocidental. **Revista Ibero-Americana de Ciências Ambientais**, v. 11, n. 5, p. 55-62, 2020.

FEARNSIDE, P. M.. Deforestation in Brazilian Amazonia: history, rates, and consequences. **Conservation Biology**, v. 19, n. 3, p. 680-688, 2005.

FEARNSIDE, P. M. Fogo e Emissão de Gases de Efeito Estufa dos Ecossistemas Florestais da Amazônia Brasileira. **ESTUDOS AVANÇADOS** 16 (44), p. 99-123, 2002.

FERREIRA, L. V.; VENTICINQUE, E.; ALMEIDA, S. O Desmatamento na Amazônia e a Importância das Áreas Protegidas. **ESTUDOS AVANÇADOS** 19 (53), p. 157-166, 2005.

GANDOUR, C.; MENEZES, D.; VIEIRA, J. P.; ASSUNÇÃO, J. Degradação Florestal na Amazônia: Fenômeno Relacionado ao Desmatamento Precisa ser Alvo de Política Pública. **Rio de Janeiro: Climate Policy Initiative**, 2021.

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.

GOMIDE, L. R. Estratificação Espacial de Compartimentos via Metaheurística Simulated Annealing em Unidades de Manejo Florestal. **Simpósio Brasileiro de Pesquisa Operacional**, Natal, Rio Grande do Norte, 2013.

HABERMANN, D. Localização Topológica e Identificação de Obstáculos por Meio de Sensor Laser 3D (LiDAR) para Aplicação em Navegação de Veículos Autônomos Terrestres. Tese (Doutorado - Programa de Pós-Graduação em Ciências de Computação e Matemática Computacional). Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, 2016.

HANSEN, M. C. et al. High-Resolution Global Maps of 21st-Century Forest Cover Change. **Science**, v. 342, n. 6160, p. 850–853, 2013.

HANSEN, M. C.; KRYLOV, A.; TYUKAVINA, A.; POTAPOV, P. V.; TURUBANOVA, S.; ZUTTA, B.; IFO, S.; MARGONO, B.; STOLLE, F.; MOORE, R.. Humid tropical forest disturbance alerts using Landsat data. **Environmental Research Letters**, v. 11, n. 3, p. 034008, 2016.

HE, K.; ZHANG, X.; REN, S.; SUN, J. Delving Deep Into Rectifiers: Surpassing humanlevel performance on imagenet classification. 2015.

HEINRICH, V. H. A.; DELAGNOL, R.; CASSOL, L. G.; ROSAN, T. M.; ALMEIDA, C. T. d.; JUNIOR, C. H. L. S.; CAMPANHARO, W. A.; HOUSE, J. I.; SITCH, S.; HALES, T. C.; ADAMI, M.; ANDERSON, L. O.; ARAGÃO, L. E. O. C.. Large Carbon Sink Potential of Secondary Forests in the Brazilian Amazon to Mitigate Climate Change. **Nature Communications**, vol. 12, n. 1, p. 1785, 2021.

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.

KALAMANDEEN, M.; GLOOR, E.; JOHNSON, I.; AGARD, S.; KATOW, M.; VANBROOKE, A.; ASHLEY, D.; BATTERMAN, S. A.; ZIV, G.; HOLDER-COLLINS, K.; PHILLIPS, O. L.; BRONDIZIO, E. S.; VIEIRA, I.; GALBRAITH, D.. Limited biomass recovery from gold mining in Amazonian forests. **Journal Of Applied Ecology**, v. 57, n. 9, p. 1730-1740, 2020.

KARPATNE, A.; EBERT-UPHOFF, I.; RAVELA, S.; BABAIE, H. A.; KUMAR, V.. Machine Learning for the Geosciences: challenges and opportunities. **Ieee Transactions On Knowledge And Data Engineering**, v. 31, n. 8, p. 1544-1554, 2019.

KATTENBORN, T.; LEITLOFF, J.; SCHIEFER, F.; HINZ, S.. Review on Convolutional Neural Networks (CNN) in vegetation remote sensing. **Isprs Journal Of Photogrammetry And Remote Sensing**, v. 173, p. 24-49, 2021.

KIEFER, J.; WOLFOWITZ, J. Stochastic Estimation of the Maximum of a Regression Function. **The Annals of Mathematical Statistics**, v. 23, n. 3, p. 462-466, 1952.

LECUN, Y.; BENGIO, Y.; HINTON, G.. Deep learning. **Nature**, v. 521, n. 7553, p. 436-444, 2015.

LEMOS, N. S. A.; CUNHA, J. M.. Analysis of Fire Risk in the Amazon: a systematic review. **Ambiente e Agua - An Interdisciplinary Journal Of Applied Science**, v. 16, n. 3, p. 1, 2021.

LI, H. Deep learning for natural language processing: advantages and challenges. **National Science Review**, v. 5, n. 1, p. 24–26, 2018.

LIRA, S. A.; NETO, A. C. Coeficientes de Correlação para Variáveis Ordinais e Dicotômicas Derivados do Coeficiente Linear de Pearson. **RECIE**, Uberlândia, v. 15, n. 1/2, p. 45-53, 2006.

LOCKS, C. J.; MATRICARDI, E. A. T.. Estimativa de Impactos da Extração Seletiva de Madeiras na Amazônia Utilizando Dados LIDAR. **Ciência Florestal**, v. 29, n. 2, p. 481-495, 2019.

LORENA, A. C.; DE CARVALHO, A. C. P. L. F. Uma Introdução às Support Vector Machines. **Revista de Informática Teórica e Aplicada**, v. 14, n. 2, p. 43–67, 2007.

MAEDA, E. E.; ABERA, T. A.; SILJANDER, M.; ARAGÃO, L. E. O. C.; MOURA, Y. M. d.; HEISKANEN, J.. Large-scale Commodity Agriculture Exacerbates the Climatic Impacts of Amazonian Deforestation. **Proceedings of the National Academy of Sciences**, v. 118, n. 7, p. e2023787118, 2021.

MANIAR, H.; RYALI, S.; KULKARNI, M. S.; ABUBAKAR, A.; SCHLUMBERGER. Machine-learning Methods in Geoscience. **SEG Technical Program Expanded Abstracts Anais...**Anaheim, California: Society of Exploration Geophysicists, 2018.

MARETTO, R.V.; FONSECA, L. M. G.; JACOBS, N.; KORTING, T. S.; BENDINI, H. N.; PARENTE, L. L. Spatio-Temporal Deep Learning Approach to Map Deforestation in Amazon Rainforest. **IEEE Geoscience and Remote Sensing Letters**, v. 18, n. 5, p. 771–775, 2021.

MARTINS, C. V.; MASCARENHAS, A. R. P. Uso de Imagens Multiespectrais na Análise da Cobertura Vegetal em Área de Concessão Florestal em Rondônia. **Anuário do Instituto de Geociências - UFRJ**. Vol. 41 - 2, p. 104-116, 2018.

MARTINS E SOUZA FILHO, P. W.; PARADELLA, W. R.; JUNIOR, C. S.; VALERIANO, D. M.; MIRANDA, F. P. Sensoriamento remoto e recursos naturais da Amazônia. **Cienc. Cult.**, São Paulo , v. 58, n. 3, p. 37-41, 2006.

MATRICARDI, E. A.T.; SKOLE, D. L.; PEDLOWSKI, M. A.; CHOMENTOWSKI, W.; FERNANDES, L. C.o. Assessment of tropical forest degradation by selective logging and fire using Landsat imagery. **Remote Sensing Of Environment**, v. 114, n. 5, p. 1117-1129, 2010.

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.

MONARD, M. C.; BARANAUSKAS, J. A. Conceitos Sobre Aprendizado de Máquina. **Sistemas Inteligentes Fundamentos e Aplicações**. 1 ed. Barueri-SP: Manole Ltda, p. 89-114, 2003.

MUNIZ, T. F.; PINHEIRO, A. S. O.. Concessão Florestal como Instrumento para Redução de Exploração Ilegal Madeireira em Unidades de Conservação em Rondônia. **Revista FAROL** – Rolim de Moura – RO, v. 8, n. 8, p. 121-142, 2019.

OLIVEIRA, R. M. F. Concessão Florestal: exploração sustentável de florestas públicas por particular. Tese (Doutorado - Faculdade de Direito da Universidade de São Paulo). Universidade de São Paulo, 2010.

PICKENS, A. H.; HANSEN, M. C.; HANCHER, M.; STEHMAN, S. V.; TYUKAVINA, A.; POTAPOV, P.; MARROQUIN, B.; SHERANI, Z.. Mapping and sampling to characterize global inland water dynamics from 1999 to 2018 with full Landsat time-series. **Remote Sensing Of Environment**, v. 243, p. 111792, 2020.

PINAGÉ, E. R.; KELLER, M.; DOS-SANTOS, M. N.; SPINELLI-ARAÚJO, L.; LONGO, M. Avaliação Temporal dos Efeitos da Exploração Madeireira Usando Dados LiDAR. **Anais XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR**, INPE, Brasil, 2015.

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.

PREVEDELLO, J. A.; WINCK, G. R.; WEBER, M. R.; NICHOLS, E.; SINERVO, Barry. Impacts of forestation and deforestation on local temperature across the globe. **PLOS ONE**, v. 14, n. 3, p. 1-18, 2019.

PRINA, B. Z.; TRENTIN, R. GMC: Geração de Matriz de Confusão a Partir de uma Classificação Digital de Imagem do ArcGIS. **Anais XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR**, INPE, Brasil, 2015.

RAMPASEK, L.; GOLDENBERG, A. TensorFlow: biology's gateway to deep learning?. **Cell Systems**, v. 2, n. 1, p. 12-14, 2016.

RAPPAPORT, D. I.; MORTON, D. C.; LONGO, M.; KELLER, M.; DUBAYAH, R.; DOS-SANTOS, M. N. Quantifying Long-term Changes in Carbon Stocks and Forest Structure From Amazon Forest Degradation. **Environmental Research Letters**, v. 13, n. 6, p. 065013, 2018.

REICHE, J.; MULLISSA, A.; SLAGTER, B.; GOU, Y.; TSENDBAZAR, N.; ODONGO-BRAUN, C.; VOLLRATH, A.; WEISSE, M. J.; STOLLE, F.; PICKENS, A. Forest Disturbance Alerts for the Congo Basin Using Sentinel-1. **Environmental Research Letters**, v. 16, n. 2, p. 024005, 2021.

RICARDO, F. Terras Indígenas na Amazônia Legal. In: VERÍSSMO, A.; ROLLA, A.; VEDOVETO, M.; FUTADA, S. de M. Áreas Protegidas na Amazônia Brasileira: avanços e desafios (p. 87). Belém/São Paulo: Imazon e ISA, 2011.

RONNEBERGER, O.; FISCHER, P.; BROX, T. U-Net: Convolutional Networks for Biomedical Image Segmentation. Em: NAVAB, N. et al. (Eds.). Medical Image Computing and Computer-Assisted Intervention – MICCAI. **Springer International Publishing**, v. 9351p. 234–241, 2015.

SAMPAIO, G.; NOBRE, C.; COSTA, M. H.; SATYAMURTY, P.; SOARES-FILHO, B. S.; CARDOSO, M. Regional Climate Change Over Eastern Amazonia Caused by Pasture and Soybean Cropland Expansion. **Geophysical Research Letters**, v. 34, n. 17, p. L17709, 2007.

SATO, L.; GOMES, V.; SHIMABUKURO, Y.; KELLER, M.; ARAI, E.; DOS-SANTOS, M.; BROWN, I.; ARAGÃO, L. Post-Fire Changes in Forest Biomass Retrieved by Airborne LiDAR in Amazonia. **Remote Sensing**, v. 8, n. 10, p. 839, 2016.

SCHNEIDER, R.; ARIMA, E.; VERÍSSIMO, A.; BARRETO, P.; JUNIOR, C. S. Sustainable Amazon: Limitations and Opportunities for Rural Development, **Inst. Do Homem e Meio ambiente da Amazônia**, Brasília, Brazil. 2000.

Serviço Florestal Brasileiro (SFB). Instituto Chico Mendes de Conservação da Biodiversidade. Flona do Jamari. Brasília, 2022. Disponível em :<<https://www.gov.br/icmbio/pt-br/assuntos/biodiversidade/unidade-de-conservacao/unidades-de-biomas/amazonia/lista-de-ucs/flona-do-jamari>>.

SHIJIE, J.; PING, W.; PEIYI, J.; SIPING, H.. Research on Data Augmentation for Image Classification Based on Convolution Neural Networks. 2017 **Chinese Automation Congress (CAC)**. **Anais...Jinan: IEEE**, 2017.

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.

SILVÉRIO, D.; SILVA, S.; ALENCAR, A.; MOUTINHO, P. Amazônia em Chamas. Nota Técnica do Instituto de Pesquisa Ambiental da Amazônia - IPAM. Brasília, 2019.

SOUZA, C.; BARRETO, P.. An Alternative Approach for Detecting and Monitoring Selectively Logged Forests in the Amazon. **International Journal Of Remote Sensing**, v. 21, n. 1, p. 173-179, 2000.

SOUZA, E. M.; SCCOTI, M. S. V. Influência da Exploração Florestal nas Populações de Espécies Ameaçadas de Extinção na Flona do Jamari, RO. **Biodiversidade Brasileira - Biobrasil**, n. 3, p. 64-73, 2020.

TAYLOR, L.; NITSCHKE, G. Improving Deep Learning using Generic Data Augmentation. 2017.

TEIXEIRA, J. F.. O que é Inteligência Artificial. 3 edição. **E-Galáxia**, 2019.

TILLMANN, E. A.; RATNIEKS, I.; NETO, G. B. Regulação e Risco Moral nas Concessões de Florestas: o caso da Floresta Nacional do Jamari. **RJLB**, Ano 2, n 1, 2016.

VANCUTSEM, C.; ACHARD, F.; PEKEL, J.-F.; VIEILLEDENT, G.; CARBONI, S.; SIMONETTI, D.; GALLEGU, 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.

WAGNER, F. H.; DALAGNOL, R.; CASAPIA, X. T.; STREHER, A. S.; PHILLIPS, O. L.; GLOOR, E.; ARAGÃO, L. E. O. C.. Regional Mapping and Spatial Distribution Analysis of Canopy Palms in an Amazon Forest Using Deep Learning and VHR Images. **Remote Sensing**, v. 12, n. 14, p. 2225, 2020.

WAGNER, F. H. et al. Using the U-net Convolutional Network to Map Forest Types and Disturbance in the Atlantic Rainforest with Very High Resolution Images. **Remote Sensing in Ecology and Conservation**, v. 5, n. 4, p. 360–375, 2019.

WAGNER, F. H.; SANCHEZ, A.; AIDAR, M. P. M.; ROCHELLE, A. L. C.; TARABALKA, Y.; FONSECA, M. G.; PHILLIPS, O. L.; GLOOR, E.; ARAGÃO, L. E. O. C.; Mapping Atlantic Rainforest Degradation and Regeneration History with Indicator Species Using Convolutional Network. **PLOS ONE**, v. 15, n. 2, p. e0229448, 2020.

WANDERLEY, L. J. M. Conflitos e Impactos Ambientais na Exploração dos Recursos Minerais na Amazônia. **Revista do Departamento de Geografia da PUC-Rio**, Rio de Janeiro, v.2, n 3, 2009.

WATZLAWICK, L. F.; KIRCHNER, F. F.; MADRUGA, P. R. A. Avaliação de Classificação Digital em Imagens de Vídeo Multiespectral Utilizando Matriz Confusão. **Revista Ciências Exatas e Naturais**, Vol. 5, no 1, 2003.