



Uma arquitetura de rede neural convolucional para detecção de alvos de desmatamento na Amazônia através de imagens SAR ICEYE

Edson Marques da Silva¹, Reginaldo Santos¹

¹Laboratório de Inteligência de Dados (LID) – Universidade Federal do Pará (UFPA)
– Belém – PA – Brazil

{edsonmarques, regicsf}@ufpa.br

Abstract. *In recent decades, solutions based on artificial satellites for observation of the earth's surface have emerged that help in the detection of deforested areas through predominantly optical technology. However, such an approach is hampered by the typical climatic conditions of the Amazon, where cloudiness makes it difficult to see some regions of interest. The use of satellites equipped with synthetic aperture radar (SAR) sensors is a viable option to overcome this inconvenience, since they are able to pass through obstacles, since they use microwaves to perform the imaging. Recently there has been an increase in the use of artificial intelligence in the task of analyzing these images in order to identify different types of land use and land cover. In this sense, the present work proposes the development of a convolutional neural network architecture capable of contributing to the monitoring of large areas of the Amazon forest through the use of machine learning techniques in order to automatically detect deforestation patterns in orbital radar images.*

Resumo. *Nas últimas décadas surgiram soluções baseadas em satélites artificiais para observação da superfície terrestre que auxiliam na detecção de áreas desmatadas por meio de tecnologia predominantemente óptica. Entretanto, tal abordagem é prejudicada pelas condições climáticas típicas da Amazônia. O uso de satélites equipados com sensores de radar de abertura sintética é uma opção viável para contornar esse inconveniente, uma vez que são capazes de transpassar obstáculos. Recentemente nota-se a ampliação do uso de inteligência artificial na tarefa de análise dessas imagens a fim de identificar diferentes tipos de uso e cobertura da terra. Nesse sentido, o presente trabalho propõe o desenvolvimento de uma arquitetura de rede neural convolucional capaz de contribuir com o monitoramento de grandes áreas da floresta amazônica através do emprego de técnicas de aprendizado de máquina com o objetivo de detectar automaticamente padrões de desflorestamento em imagens de radar orbital.*

1. Introdução

A preservação da Floresta Amazônica é um assunto de grande relevância para o cenário ecológico global. Cobrindo vários milhões de quilômetros quadrados, a região tem a maior floresta tropical e sistema fluvial do mundo, desempenhando um papel muito importante para o ecossistema do planeta. Entretanto, nos últimos anos, a Amazônia passou por mudanças drásticas na cobertura da terra, decorrentes do desmatamento que foi se intensificando para satisfazer aos mais diversos usos, alguns dos quais associados a atividades ilícitas [Ometto et al. 2014].

O desmatamento da Amazônia Brasileira atingiu seus maiores níveis nos anos de 1995 e 2004, enquanto em 2012 conseguiu reduzir à menor taxa histórica, provocada por pressões internacionais e implementação de políticas públicas como o Plano de Ação para Prevenção e Controle do Desmatamento na Amazônia Legal (PPCDAM) [Silva-Junior et al. 2021]. Contudo, devido ao enfraquecimento das ações de controle ambiental, nos últimos anos observa-se um crescimento gradual da área desmatada anualmente na Amazônia Legal. Como consequências disso, ocorrem a perda de biodiversidade, prejuízos ao ciclo da água, além de favorecimento ao aquecimento global, sobretudo na ocorrência de queimadas, à medida que são emitidos gases que contribuem para acelerar o processo do efeito estufa.

Sabendo da complexidade para o monitoramento da Amazônia Legal Brasileira, surgiram iniciativas governamentais baseadas na utilização de imagens de satélite com o objetivo de controlar e prevenir o desmatamento na região, dentre as quais se destacam o Programa de Monitoramento da Floresta Amazônica Brasileira por Satélite (PRODES) e o Sistema de Detecção de Desmatamentos em Tempo Real (DETER), mantidos pelo Instituto Nacional de Pesquisa Espaciais (INPE), que fornecem informações detalhadas sobre o desflorestamento, gerando relatórios com taxas anuais e alertas de desmatamento [Diniz, et al. 2015].

Para realizar a detecção de áreas desmatadas o INPE utiliza uma metodologia que aproveita predominantemente as características do espectro visível, a partir dos satélites Landsat-8, SENTINEL-2 e CBERS-4 [INPE 2021]. Como a ocorrência de nebulosidade é frequente na região amazônica, principalmente entre os meses de Outubro a Abril, é interessante contornar esse inconveniente de modo a incrementar a disponibilidade de dados de desmatamento durante todo o período do ano.

Por isso, começou-se a monitorar o desmatamento da Amazônia utilizando imagens de radar orbital, que usa tecnologia de imageamento por microondas para superar tais obstáculos, e assim prover alertas de desmatamento no período de alta densidade de nuvens na Amazônia, de modo complementar ao DETER.

Em tal contexto, almeja-se contribuir no processo de análise das imagens de radar orbital por meio da aplicação de técnicas de inteligência computacional, propondo uma arquitetura de rede neural convolucional com a capacidade de automatizar a detecção das áreas desmatadas em imagens SAR obtidas por meio da constelação de satélites ICEYE.

2. Contextualização e motivação

O uso de imagens de satélite para monitoramento do desmatamento na Amazônia, iniciado na década de 80 no Brasil, melhorou significativamente a extração de informações territoriais de interesse nessa região. Contudo, durante muito tempo, a maior parte do tratamento e análise de dados era realizada manualmente por

especialistas, o que se mostrou caro e demorado. Com o aperfeiçoamento das tecnologias de aquisição e o incremento da capacidade computacional, atualmente existem diversas ferramentas capazes de auxiliar os analistas no processamento digital de imagens, porém também se observa um aumento considerável no volume de dados disponíveis, impulsionado pelo crescimento do número de fontes de imagens de satélite, com resoluções cada vez maiores, e o surgimento de novas alternativas de sensoriamento remoto. Dessa forma, é bastante desejável automatizar esse processo, visando torná-lo mais ágil e eficiente.

Nesse sentido, várias abordagens de classificação de imagens têm sido utilizadas no campo da análise de dados de sensoriamento remoto, muitas delas utilizando métodos de processamento digital de sinais, e mais recentemente, empregando inteligência artificial [Canty 2014]. Atualmente, destaca-se, nesse campo, aplicações de aprendizado de máquina, baseadas em aprendizado profundo, que ganharam notoriedade ao auxiliar na resolução de problemas complexos e superar métodos de referência em reconhecimento de padrões e classificação de imagens.

Embora a maioria dos trabalhos de redes neurais artificiais aplicados à visão computacional se concentrem na análise de imagens ópticas, a aplicação a imagens de radar é de particular interesse para o estudo em questão, haja vista a dificuldade encontrada no monitoramento da Amazônia durante o período de chuvas ou grande nebulosidade na região, uma vez que os satélites com tecnologia óptica não são capazes de atravessar as nuvens para mostrar imagens da camada de interesse, prejudicando a realização da observação da superfície terrestre.

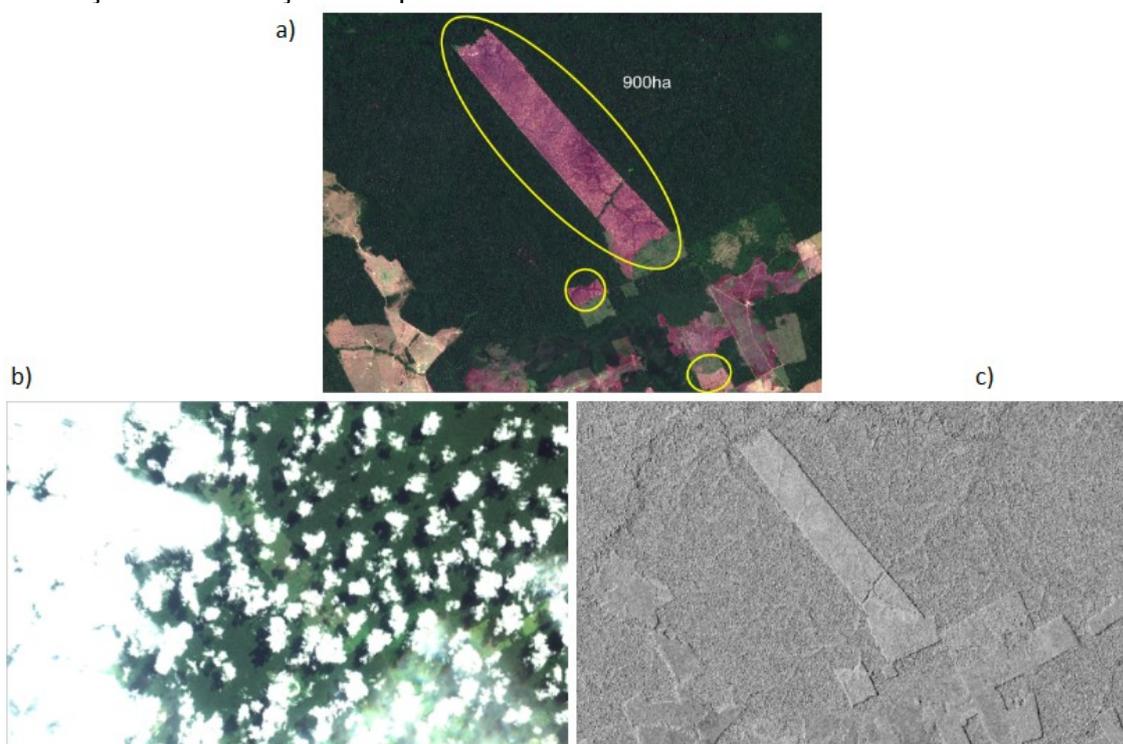


Figura 1. a) Áreas de 900 ha desmatadas. b) Imageamento óptico encoberto por nuvens c) Imagem capturada por radar [CENSIPAM 2021]

Na Figura 1, verifica-se a diferença entre o imageamento de uma área encoberta por nuvens capturada por um sensor óptico e por radar. Na Figura 1a são evidenciadas áreas desmatadas que totalizam 900 hectares, em imageamento óptico com condições

climáticas ideais, sem nebulosidade. Já na Figura 1b é possível perceber que as nuvens estão encobrindo grande parte das áreas de interesse, enquanto na Figura 1c, apesar da propriedade da imagem em escala de cinza, a mesma área, sob condições semelhantes, não tem a interferência das nuvens na formação da imagem. Essa característica confere aos sensores baseados em radar mais agilidade na identificação de áreas de desmatamento, agregando grande valor à geração de alertas de atividades suspeitas para facilitar a ação dos órgãos de fiscalização ambiental na Amazônia.

Sobre o assunto, encontra-se na bibliografia o trabalho de [Navale e Haldar 2019] em que os pesquisadores usaram dados SAR Sentinel-1 multi-temporais para classificação da área de Saharanpur nas Planícies indo-gangéticas com conjuntos de dados mensais de dezembro, janeiro e fevereiro e polarização VV e VV/VH. Segundo o artigo, foram usados algoritmos Support Vector Machine (SVM), *Random Forest* (RF), Árvore de Decisão (DT) e Rede Neural Artificial (RNA) com seis combinações de bandas diferentes para classificar os dados em 6 classes. Os autores discutiram a performance e usabilidade dos algoritmos para detecção das classes de classificação: água, leito de rio seco, área urbana, floresta, agricultura e pomar.

Na mesma vertente, em [Carranza-García et al. 2019] foi proposta uma rede neural convolucional geral, com arquitetura e parametrização fixas, para alcançar alta precisão na classificação de uso e cobertura da terra sobre dados de sensoriamento remoto de diferentes fontes, como radar e hiperespectral. Foi apresentada uma metodologia para realizar uma comparação experimental rigorosa entre o método de Deep-learning proposto e outros algoritmos de Machine Learning como máquinas de vetores de suporte (SVM), Random Forest e K-nearest-neighbors (KNN). A análise realizada demonstra que a rede neural convolucional supera as demais técnicas, alcançando um alto nível de desempenho para todos os conjuntos de dados estudados, independentemente de suas diferentes características.

Já em [Kuck et al. 2021], foram testados diferentes modelos pré-treinados de redes neurais convolucionais para detecção de mudanças associadas à degradação florestal em produtos bitemporais obtidos a partir de um par de imagens SAR COSMO-SkyMed adquiridas antes e depois da extração na Floresta Nacional do Jamari. Os resultados indicaram que os dados SAR multitemporais da banda X têm potencial para monitorar a extração seletiva em florestas tropicais, especialmente em combinação com as redes neurais convolucionais.

3. Metodologia

O principal foco de interesse, neste estudo, para detecção de alvos nas imagens serão áreas de desflorestamento por corte raso. A saber, existem dois tipos de desmatamento: por corte raso ou por degradação florestal. O desmatamento por corte raso provoca a remoção completa da cobertura florestal em um curto intervalo de tempo, sendo substituída por outras coberturas e usos, por exemplo, pastagem, agrícola ou urbano. Já a degradação florestal é um processo lento e progressivo de degeneração da cobertura vegetal, e por isso mais difícil de detectar por satélite, normalmente, praticado para extração seletiva de madeira [INPE 2021].

A metodologia adotada consistiu, primeiramente, em realizar o levantamento de imagens de radar, fornecidas pelo Centro Gestor e Operacional do Sistema de Proteção da Amazônia (CENSIPAM), de modo a compor um banco de dados para serem utilizados nas etapas seguintes do desenvolvimento. Após isso, deu-se início à fase de seleção e pré-processamento dos dados visando a composição dos conjuntos de

treinamento e teste da rede neural. Então, foram implementados os algoritmos de redes neurais convolucionais com aprendizado profundo para classificar as imagens de radar com a finalidade de reconhecer padrões que correspondam a áreas de desflorestamento por corte-raso. Estas etapas foram desenvolvidas com o auxílio de ferramentas como Python, com as bibliotecas Tensorflow, Keras, Rasterio, Geopandas, e do software QGIS para tratamento dos dados.

Foi utilizada predominantemente a abordagem quantitativa para avaliar a melhor estratégia de uso das técnicas de redes neurais com aprendizado profundo para classificar as imagens de radar obtidas pelos sensores satelitais, com o objetivo de reconhecer os padrões desejados. A avaliação dos resultados experimentais será realizada por meio de parâmetros quantificáveis como acurácia, taxa de erro e matriz de confusão.

4. Área de estudo e dados

Foram obtidas imagens de satélite orbital do sensor SAR Iceye, dentro dos limites do estado de Roraima, entre os meses de Outubro de 2021 e Janeiro de 2022, quando tipicamente as condições climáticas são mais adversas na região. Os satélites Iceye utilizam frequências da banda X para imageamento da superfície terrestre, em polarização vertical no envio e recepção do feixe de microondas (polarização VV), fornecendo imagens em modo strip, em tons de cinza, de único canal, com resolução espacial (tamanho real do pixel da imagem) de aproximadamente 3 metros [ICEYE 2022].

Essas imagens correspondem às áreas de monitoramento de desmatamento e foram devidamente ortoretificadas e analisadas por especialistas em sensoriamento remoto, sem considerar o aspecto temporal, para identificação de polígonos que caracterizam desflorestamento nessa região, mais especificamente por corte-raso. Dessa forma, temos a diferenciação de duas classes que compõem o conjunto de dados do experimento, nomeadas como corte-raso e floresta.

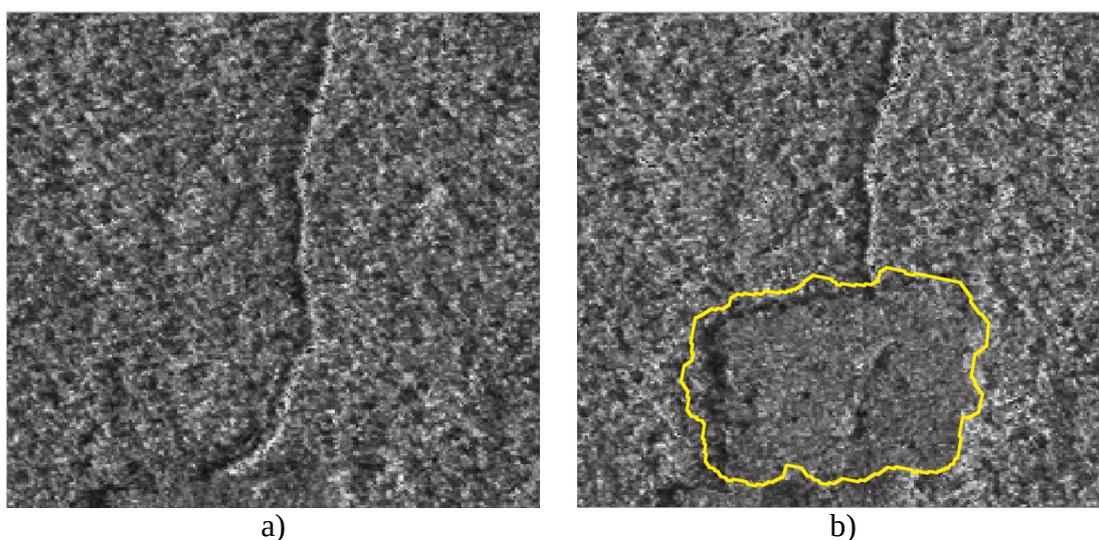


Figura 2. Imagem SAR Iceye a) área não desmatada. b) desmatamento por corte raso

A imagem bruta proveniente do satélite, com tamanho de dezenas de quilômetros, foi tratada através de um script de pré-processamento, com a finalidade de

obter recortes contendo os polígonos pré-classificados, além de realizar normalizações nos valores de pixel e tamanho da amostra, resultando em um dataset com 200 imagens de 160x160 pixels em cada classe. Em seguida, o dataset foi particionado na proporção de 80% para treinamento e 20% para testes. Na Figura 2 é apresentado um exemplo de imagens obtidas neste processo, referentes a uma mesma área em diferentes instantes de tempo, evidenciando uma mudança na textura das imagens entre a floresta ainda não desmatada e o seu estado após sofrer desflorestamento por corte raso.

5. Arquitetura

A arquitetura proposta consiste de um modelo sequencial implementado na linguagem Python, com as bibliotecas Tensorflow e Keras, composta por treze camadas, incluindo camadas convolucionais, camadas de *pooling*, camadas de *dropout* e camadas densas, tipicamente utilizadas em aplicações de processamento de imagens e reconhecimento de padrões.

Inicialmente, foram configuradas 3 camadas convolucionais intercaladas com camadas de *pooling* com tamanho de *pool* 2x2, sendo a primeira camada convolucional com 32 filtros, tamanho de kernel 3x3 e função de ativação 'relu' e as demais camadas com 64 filtros. Essas camadas são responsáveis por extrair características das imagens de entrada. As camadas seguintes são camadas de *dropout* com taxa de 0.25, que tem a finalidade de regularizar o modelo e evitar *overfitting*, e camada *Flatten* que serializa as características extraídas pelas camadas anteriores em um vetor unidimensional.

A nona camada é uma camada densa com 256 neurônios e função de ativação 'relu', onde são aprendidos os padrões complexos a partir das características extraídas pelas camadas anteriores, seguida por outra camada de *dropout* com taxa de de 0.5, repetindo-se essa mesma estrutura nas duas camadas posteriores. A décima terceira e última camada é uma camada densa com 2 neurônios e função de ativação 'softmax', a qual é responsável por produzir a saída final do modelo.

6. Resultados e discussão

Os resultados mostraram que a implementação do modelo de arquitetura de rede neural para detecção de desmatamento por corte raso, utilizando imagens SAR ICEYE na Amazônia apresentou um desempenho satisfatório, uma vez que foi alcançada uma acurácia de 96,25% no experimento.

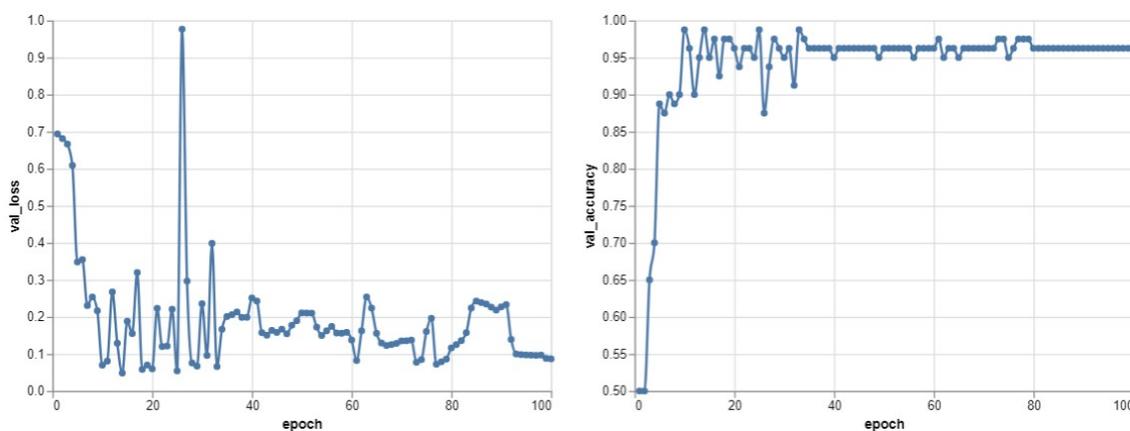


Figura 3. Gráfico da perda e acurácia de teste

Esse indicador foi alcançado num cenário em que a rede neural foi treinada por 100 épocas, com um conjunto de treinamento de 160 imagens e conjunto de testes de 40 imagens. A Figura 3 ilustra o comportamento do modelo durante a fase de testes. Nela podemos observar que a arquitetura convergiu para a generalização por entre a época 30 e 40, estabilizando acima de 95% de acurácia.

A saída da função de ativação da última camada da arquitetura da rede neural retorna valores binários, onde 0 representa a classe “corte raso” e 1 representa a classe “floresta”. Na Tabela 1 temos a matriz de confusão que consolida os resultados dos testes, apresentando os erros e acertos em cada classe. Percebe-se que durante a predição houve dois erros na classe “corte raso” e apenas um erro na classe “floresta”.

Tabela 1. Matriz de confusão do modelo

Matriz de Confusão		Classe predita	
		Corte-raso	Floresta
Classe original	Corte-raso	38	2
	Floresta	1	39

Na Tabela 2, são apresentados os dados estatísticos do modelo, calculados a partir da matriz de confusão, como: acurácia, precisão, sensibilidade (*recall*), especificidade e f1-score. Destas métricas a mais importante é a acurácia, pois avalia diretamente o total de acertos do modelo. Porém, não menos importantes, a precisão avalia a quantidade de verdadeiros positivos sobre a soma de todos os valores positivos, a sensibilidade mede a capacidade do método de detectar com sucesso classificações positivas, enquanto a especificidade avalia a capacidade do método identificar resultados negativos. Já o f1-score é uma média harmônica que considera a precisão e a sensibilidade.

Tabela 2. Resultados estatísticos do modelo

Acurácia	Precisão	Sensibilidade	Especificidade	F1-score
0,96	0,97	0,95	0,97	0,96

7. Conclusão

Neste trabalho, foi proposto o desenvolvimento de uma arquitetura de rede neural convolucional capaz de contribuir com o monitoramento de grandes áreas da floresta amazônica através do emprego de técnicas de aprendizado de máquina com o objetivo de detectar automaticamente padrões de desflorestamento em imagens de radar orbital. O modelo foi treinado em um conjunto de dados de imagens de radar da Amazônia e obteve uma acurácia de classificação acima de 95%. Os resultados deste trabalho demonstram o potencial da rede neural testada para o monitoramento do desflorestamento na Amazônia.

Dessa forma, observa-se a grande relevância na implementação, teste e otimização dos algoritmos para identificação de alvos de desmatamento na Amazônia a partir de dados de sensores orbitais de radar de abertura sintética (SAR), fazendo uso de técnicas de aprendizado de máquina, a fim de auxiliar na análise das imagens geoespaciais, facilitando o diagnóstico de ilícitos e contribuindo para tornar mais eficaz a geração de alertas de ocorrência de retirada ilegal da cobertura vegetal na Amazônia.

Referências

- Canty, M. J. Image analysis, classification and change detection in remote sensing: with algorithms for ENVI/IDL and Python. 3 ed. New York: CRC Press, 2014. 576 p.
- Carranza-García, M. ; García-Gutiérrez, J. ; Riquelme, J.C. (2019). "A Framework for Evaluating Land Use and Land Cover Classification Using Convolutional Neural Networks" *Remote Sensing* 11, no. 3: 274.
- CENSIPAM. Projeto Amazônia SAR: desenvolvimento operacional e primeiros resultados na identificação do desmatamento com imagens de Radar Orbital. Disponível em: <<http://www.sipam.gov.br/projeto-amazonia-sar>>. Acesso em: 18 jan. 2021.
- Diniz, C.G.; de Almeida Souza, A.A.; Santos, D.C.; Dias, M.C.; da Luz, N.C.; de Moraes, D.R.V.; Maia, J.S.; Gomes, A.R.; da Silva Narvaes, I.; Valeriano, D.M.; et al. DETER-B: The new Amazon near real-time deforestation detection system. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* 2015, 8, 3619–3628.
- Instituto Nacional de Pesquisas Espaciais (INPE). Estimativa de desmatamento por corte raso na Amazônia Legal para 2021 é de 13.235 km² disponível em: <<https://www.gov.br/inpe/pt-br/assuntos/ultimas-noticias/divulgacao-de-dados-prodes.pdf>>.2021.
- Instituto Nacional de Pesquisas Espaciais (INPE). Metodologia Utilizada nos Projetos Prodes e Deter. Disponível em: <<http://mtc-m21c.sid.inpe.br/col/sid.inpe.br/mtc-m21c/2021/01.25.18.31/doc/publicacao.pdf>>. Acessada em 17 de Fevereiro de 2022.
- ICEYE SAR Product Documentation. Disponível em: <<https://iceye-ltd.github.io/product-documentation/5.0/>>. Acessada em 7 de Junho de 2022.
- Kuck, T.N.; Silva Filho, P.F.F.; Sano, E.E.; Bispo, P.d.C.; Shiguemori, E.H.; Dalagnol, R. Change Detection of Selective Logging in the Brazilian Amazon Using X-Band SAR Data and Pre-Trained Convolutional Neural Networks. *Remote Sensing* 13, no. 23. 2021.
- Navale, A. ; Haldar, D. (2019) "Evaluation of machine learning algorithms to Sentinel SAR data" . *Spatial Information Research*.
- Ometto, J. ; Aguiar, A. P. ; Martinelli, L. Amazon deforestation in Brazil: Effects, drivers and challenges. *Carbon Management*, v. 2, n. 5, p. 575-585, abr./2014.
- Oveis, A. H.; Guisti, E.; Ghio, S. ; Martorella, M. "A Survey on the Applications of Convolutional Neural Networks for Synthetic Aperture Radar: Recent Advances," in *IEEE Aerospace and Electronic Systems Magazine*, 2021.
- Silva-Junior, C. ; Moreira Pessôa, A. C. ; Carvalho, N. ; dos Reis, J. ; Anderson, L. ; Aragão, L. The Brazilian Amazon deforestation rate in 2020 is the greatest of the decade. *Nature Ecology & Evolution*. 5, 2021, 144-145.