

Estudo Comparativo da Detecção de Desmatamento em Cenas Sentinel-1 da Floresta Amazônica

Igor B. C. Correia, Mylène C.Q. Farias,
Edson M. Hung
Departamento de Engenharia Elétrica
Universidade de Brasília (UnB)
Brasília, Distrito Federal
igor.rabbit99@gmail.com

Ulisses S. Guimarães, Thiago B. Rodrigues,
Hélcio Vieira Jr
Centro Gestor e Operacional do Sistema
de Proteção da Amazônia
CENSIPAM
Brasília, Distrito Federal

Resumo—Diante das limitações das imagens de satélites ópticos, o radar de abertura sintética (SAR) se destaca pela resistência a condições climáticas adversas. Contudo, o reconhecimento preciso de áreas desmatadas nas imagens SAR é desafiador devido ao ruído “speckle” e a variabilidade dos objetos. Neste artigo, realizamos um experimento *online* com participantes voluntários que identificaram áreas desmatadas em imagens SAR. Para isto, desenvolvemos um software que permite que os participantes façam anotações nas imagens SAR, delimitando áreas desmatadas. Com os resultados deste experimento, foi possível analisar a relação entre o nível de experiência autodeclarada dos participantes e a precisão na detecção de áreas desmatadas. Também comparamos o desempenho humano e o desempenho obtido com um modelo automático baseado na arquitetura UNet. Os resultados mostram que um maior conhecimento em sensoriamento remoto ou SAR não garante anotações de qualidade. Além disso, o desempenho da UNet supera o desempenho obtido com humanos na tarefa. O estudo reforça o potencial de aprendizado profundo na detecção de desmatamento, enfatizando a necessidade de aprimoramento contínuo das arquiteturas e da capacitação de especialistas.

Palavras-chave—SAR, Deep Learning, CNN, Desmatamento

I. INTRODUÇÃO

O desmatamento florestal tem impactos múltiplos e abrangentes, sendo uma questão ambiental cada vez mais preocupante mundialmente. Além de representar uma ameaça à biodiversidade, o desmatamento contribui significativamente para a mudança climática [1] e compromete a sustentabilidade dos ecossistemas naturais [2]. Portanto, a monitoração e a detecção de áreas desmatadas se configuram como um dos problemas mais urgentes e relevantes da atualidade.

A detecção de áreas desmatadas pode ser realizada utilizando imagens capturadas por satélites ópticos, como o Landsat [3], Sentinel-2 [4] e GeoEye-1 [5], ou por radares de abertura sintética (SAR, do inglês *Synthetic Aperture Radar*), como o Sentinel-1 [6], TerraSAR-X [7] e RadarSAT [8]. A Figura 1 mostra uma imagem adquirida com SAR e uma imagem adquirida com satélites ópticos. As imagens adquiridas por satélites ópticos são muito afetadas por condições meteorológicas, como chuvas intensas, cobertura de nuvens e neblina, que prejudicam a visibilidade das áreas nas imagens adquiridas. Por esta




Figura 1. Comparação entre uma imagem SAR (à direita) e uma imagem óptica (à esquerda) da mesma região. Fonte: *Very-High-Resolution SAR Imaging with DGPS-Supported Airborne X-Band Data* [9]

razão, as imagens capturadas por SARs são consideradas como sendo mais adequadas para detecção de áreas desmatadas, uma vez que essas imagens são menos afetadas pelas condições climáticas.

Ao contrário dos satélites ópticos, os SARs possuem sensores ativos que emitem pulsos de microondas em uma frequência típica de operação que varia de centenas de megahertz (MHz) a vários gigahertz (GHz) [10]. Esses pulsos de microondas são direcionados para a superfície da Terra e, em seguida, o SAR registra o retorno desses pulsos, refletidos pelos objetos presentes na superfície. A partir da diferença de tempo entre o momento em que os pulsos são emitidos e o momento em que os pulsos refletidos retornam ao radar, o SAR cria as imagens, utilizando a técnica de interferometria de radar de abertura sintética (InSAR) [11] para obter uma alta resolução espacial. A técnica InSAR combina e processa os vários pulsos de micro-ondas recebidos em diferentes posições do radar ao longo do movimento do satélite. As ondas emitidas têm a capacidade de penetrar na maioria das coberturas de nuvens, permitindo que o radar obtenha informações mesmo em condições atmosféricas adversas. Portanto, as imagens SAR são valiosas para a detecção de áreas desmatadas em regiões tropicais, como a Amazônia,




Figura 2. Ilustração da geometria da imagem SAR. O parâmetro r_0 se refere à menor distância de aproximação; θ_a é a largura do feixe, e v é a velocidade do sensor. Fonte: *A tutorial on synthetic aperture radar* [12], adaptada.

onde a presença de nuvens e neblina é frequente.

Apesar da vantagem de independência climática, a detecção precisa de áreas desmatadas em imagens SAR é uma tarefa desafiadora devido à alta quantidade de ruído *speckle* das imagens capturadas e à variabilidade da aparência dos objetos. Atualmente, existem algumas propostas de sistemas automáticos para detecção de áreas desmatadas. Por exemplo, Pimenta *et al.* [13] desenvolveram um sistema a detecção de desmatamento em florestas tropicais baseado na técnica de neuroevolução (NEAT). Este método demonstrou uma eficácia significativa na identificação de áreas recentemente desmatadas, superando técnicas de monitoramento tradicionais.

Zhu *et al.* [14] e Zheng *et al.* [15] propuseram métodos baseados em redes neurais convolucionais (CNN) para detecção de alvos em imagens SAR. Zhu *et al.* utilizaram transferência de aprendizado para lidar com a escassez de dados, otimizando a rede para a tarefa de detecção de alvos, o que resultou em uma maior velocidade de detecção e um número menor de falsos positivos. Por outro lado, Zheng *et al.* introduziram um método que emprega tanto atributos aprendidas por uma CNN quanto atributos extraídos manualmente. Estes atributos são processados em sub-redes paralelas e, posteriormente, fundidos para a classificação final, resultando em uma melhora no desempenho da detecção. Essas abordagens representam avanços na detecção de alvos em imagens SAR, porém a aplicação desses métodos para detecção de desmatamento florestal em imagens SAR, considerando o ruído *speckle* e a variabilidade dos objetos, continua sendo um desafio.

O primeiro objetivo deste trabalho é estimar a capacidade de seres humanos identificarem áreas desmatadas em imagens SAR, levando em consideração a experiência de cada indivíduo na área. Com este objetivo, realizamos um experimento subjetivo no qual participantes voluntários realizaram a rotulação de áreas desmatadas em um conjunto de 50 imagens SAR da região amazônica capturadas com o satélite Sentinel-1A [6]. O experimento foi realizado online utilizando um *software* para a rotulação de imagens que foi desenvolvido para este fim. O segundo objetivo do nosso trabalho é avaliar o desempenho de um modelo automático para detecção de áreas desmatadas, comparando este desempenho com o desempenho de seres

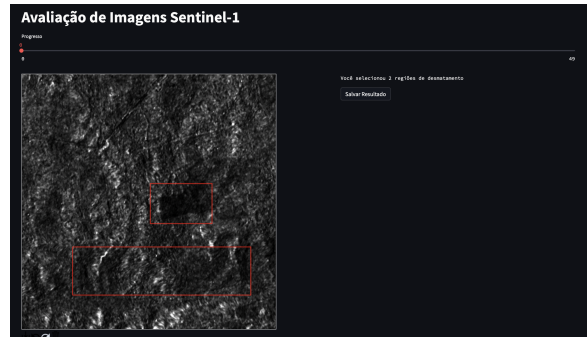


Figura 3. Captura de tela mostrando a interface do sistema desenvolvido. O voluntário deve marcar as caixas delimitadoras utilizando 'clique' e 'arraste do mouse'. Para finalizar, o usuário deve clicar no botão 'Salvar Resultado'. Software disponível em sar.igorbispo99.com.

humanos. O modelo considerado é baseado na arquitetura UNet, proposta em 2015 por Olaf *et al.* [16]. Apesar da UNet ser uma arquitetura originalmente desenvolvida para a segmentação de imagens médicas, esta arquitetura apresenta bom desempenho em uma ampla gama de tarefas de segmentação, desde a detecção de rachaduras [17] e de defeitos em tecidos [18], até a detecção de desmatamentos em imagens de satélite [19].

Este artigo está dividido da seguinte maneira. Na Seção II, descrevemos a metodologia experimental utilizada para coletar e agregar as anotações dos diferentes participantes. Na Seção III, apresentamos a análise dos resultados coletados, incluindo uma análise da relação do nível de experiência e o desempenho da classificação do modelo de CNN treinado na tarefa de detecção. Finalmente, na Seção V, apresentamos nossas conclusões e sugestões para trabalhos futuros.

II. METODOLOGIA EXPERIMENTAL

Apesar de existirem bons serviços de anotação, como o CVAT [20], optamos por desenvolver um sistema de anotação personalizado, mais simples e com uma interface mais enxuta. A Figura 3 mostra um *screenshot* do sistema desenvolvido. O sistema é baseado no *Streamlit*, que é uma plataforma de código aberto que permite a criação rápida e eficiente de aplicativos web. Adaptamos o código, implementando funções para coletar anotações e salvar os resultados em um banco de dados relacional. Utilizando esta plataforma online, os participantes visualizaram e anotaram as áreas desmatadas em imagens SAR.

As imagens utilizadas no experimento foram coletadas pelo radar Sentinel-1A [6] que é um dos satélites do programa Copernicus [21]. Ao todo, foram disponibilizadas 50 imagens para cada participante. As imagens correspondem a recortes de tamanho 512×512 extraídos de uma captura SLC já processada com calibração radiométrica [22], correção de órbita, *multilook* [11] e filtro *anti-speckle* [23] do radar Sentinel-1A. A captura foi feita no dia 27/07/2021 e pode ser obtida através do portal *Open Access Hub* da Agência Espacial Europeia¹. Para o experimento, apenas a banda VV do sinal foi utilizada, tanto para a classificação por rede neural quanto para o experimento com voluntários.

¹<https://scihub.copernicus.eu>




Figura 4. Composição de recortes de uma cena Sentinel-1 ao lado da mesma cena rotulada e das caixas delimitadoras desejáveis.

Para gerar a rotulação utilizada como gabarito para os dados (*ground-truth*), utilizamos a técnica descrita por Paulo Tavares *et al.* [24] que faz uso tanto dos dados SAR do Sentinel 1 como dos dados ópticos do Sentinel-2. As imagens estão organizadas em um arranjo co-orbital, sendo a revisita feita em um intervalo de no máximo 3 dias. Estas imagens foram selecionadas no período que antecede o inverno amazônico com taxas de nebulosidade inferiores a 2%. As imagens do Sentinel 1 e Sentinel 2 são co-localizadas e possuem uma amostragem do terreno da ordem de 10m, sendo referenciadas no sistema de coordenadas geográficas WGS84. Para gerar o *ground-truth*, foram coletadas entre 5.000 a 10.000 faces, sendo utilizado o Random Forest com os seguintes parâmetros: N-try igual a 1.000, M-tree igual a 7, 5.000 amostras aleatórias divididas em 30% para validação e 70% pra treinamento. De acordo com a metodologia do Prodes do Inpe, foram definidas 4 classes de rotulação: floresta, desmatamento, água e não-floresta. Essa classificação foi revisada por 5 especialistas e 10 estagiários e bolsistas. Na Figura 5 estão representadas dois exemplos de imagens e das suas respectivas máscaras de *ground-truth*.

Antes da sessão experimental, os participantes assistiram a um vídeo com uma introdução do problema da detecção de desmatamento, uma descrição do processo de rotulação de imagens e uma demonstração do software desenvolvido. Mais especificamente, os participantes visualizaram vários exemplos de imagens SARs, como ilustrado na Figura 4, onde as regiões desmatadas estão demarcadas com um retângulo verde. Estas áreas demarcadas são as regiões de referência (*ground-truth*) do banco de dados utilizado. Os participantes foram orientados a marcar as regiões desmatadas utilizando o menor retângulo possível para cada área desmatada não-contígua.

III. MODELO AUTOMÁTICO DE DETECÇÃO DE ÁREAS DESMATADAS

O modelo automático para detecção de áreas desmatadas é baseado na arquitetura UNet [16], ilustrada na Figura 6. A UNet é uma arquitetura simétrica de codificação e decodificação que aproveita a natureza espacial das imagens para produzir segmentações precisas ao nível do píxel [16]. A parte de codificação da arquitetura é responsável pela extração de características, enquanto a




Figura 5. Recortes de capturas da banda VV processada Sentinel 1 ao lado da máscara correspondente obtida pelo processo descrito.

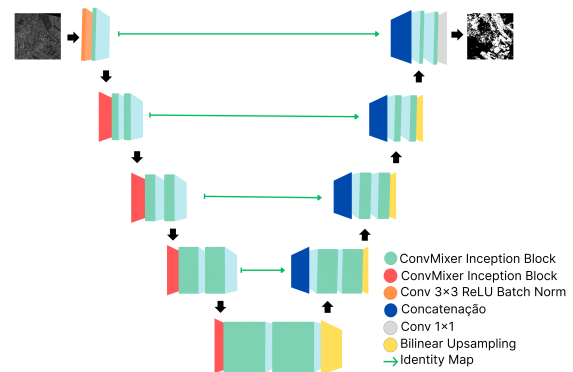


Figura 6. Representação da arquitetura UNet. A entrada da rede é o recorte 512x512 processado e a saída é uma máscara binária contendo a marcação do desmatamento píxel a píxel.

parte de decodificação utiliza estas características para prever a segmentação da imagem. Os saltos de conexão entre as partes de codificação e decodificação ajudam a preservar as informações espaciais detalhadas [16].

Apesar de existirem outros modelos para segmentação de imagens, como o *framework* InternImage proposto por Wang *et al.* [25] que é baseado em redes transformadoras, escolhemos a UNet devido à sua simplicidade de implementação, treinamento ágil e eficácia demonstrada em imagens de satélite [26]. A escolha se justifica, em particular, pela capacidade do modelo de operar eficientemente em recursos de hardware limitados e pela sua comprovada adequação para imagens produzidas por SARs. Nos experimentos conduzidos, a UNet não apenas obteve desempenhos próximos aos obtidos por modelos do estado da arte, mas também superou rotuladores humanos em precisão e tempo de processamento na detecção de desmatamento em imagens SAR. Essa superioridade demonstrada torna a UNet uma escolha prática e eficiente para a tarefa em questão.

A implementação da rede UNet foi feita na linguagem Python 3.7 com PyTorch versão 1.3. O modelo foi treinado em uma base de dados contendo 1.279 recortes de tamanho 512x512 extraídos de 4 cenas SLC Sentinel-1A da floresta Amazônica, capturadas em 27/07/2019,




Figura 7. Composição com dois recortes 512x512 Sentinel-1 submetidos para avaliação com as demarcações sobrepostas, a máscara gerada pelo processo de consolidação descrito na seção II ao centro, e o *ground-truth* à direita.

04/08/2020, 13/08/2020 e 30/08/2021. As imagens foram pré-processadas seguindo a mesma cadeia de operações utilizada para gerar as imagens submetidas ao sistema online de rotulação. Vale ressaltar que não há interseção entre as áreas das cenas utilizadas no treinamento da rede neural e as áreas utilizadas para os testes comparativos. O modelo foi treinado durante 5 épocas, com *batch-size* de tamanho 16 e taxa de *learning rate* dinâmica regressiva, iniciando com um valor gual a 0,00001. O RMSProp foi utilizado como otimizador de gradiente. O treinamento do modelo foi feito em uma máquina Windows 11 com processador i7-11700K e GPU RTX 3080.

IV. RESULTADOS EXPERIMENTAIS

Para analisar os resultados do experimento subjetivo, agrupamos as anotações de demarcações dadas por diferentes voluntários a uma mesma imagem. Para cada demarcação de desmatamento dada por cada participante a uma determinada imagem, o valor 1 é adicionado à máscara de desmatamento. Em seguida, cada um dos pixels da máscara é dividido pela quantidade de participantes que anotaram aquela imagem, de forma a normalizar os valores das máscaras entre 0 e 1. Por fim, um limiar de 0,5 é aplicado à imagem, de forma que os valores abaixo de 0,5 são considerados negativos e valores acima de 0,5 são considerados positivos. A Figura 7 mostra todos os retângulos marcados pelos participantes para duas das imagens de teste e a máscara correspondente gerada com a estratégia proposta. As caixas da mesma cor foram marcadas pela mesmo participante.

No total, 24 indivíduos participaram do experimento. Os participantes possuíam diferentes níveis de experiência. No começo do experimento, os participantes relataram o seu nível de experiência em sensoriamento remoto e radares de abertura sintética utilizando uma escala de 0 a 4, onde 4 indica que o participante é um especialista e 0 indica que ele não tem nenhuma experiência no assunto. As Figuras 8 (a) e (b) mostram gráficos ilustrando a distribuição da experiência dos participantes nos tópicos sensoriamento remoto e radares de abertura sintética, respectivamente. Destes gráficos, pode-se observar que a experiência dos participantes na área de sensoriamento remoto variou bastante, com 34% não tendo nenhuma




Figura 8. Distribuição da experiência autodeclarada dos participantes na área de: (a) sensoriamento remoto e (b) SAR.

experiência, 21% tendo pouca experiência, 29,8% tendo alguma experiência, 12,8% tendo um bom nível de experiência e 2,1% sendo especialistas no assunto. Já em radares de abertura sintética, cerca de metade (51,1%) dos participantes não tinham nenhuma experiência, 17% tinham pouca experiência, 21,3% tinham alguma experiência e 10,6% tinham um bom nível de experiência.

Tendo como referência as marcações *ground-truth* das imagens que mostram as áreas de desmatamento confirmado, analisamos o desempenho dos participantes e do modelo calculando as seguintes métricas: precisão, F1 (média harmônica entre a precisão e *recall*), intersecção sobre a união (IOU, do inglês Intersection Over Union) e área sob a curva (AUC, do inglês area under the curve). Estas métricas de desempenho são consideradas padrão na literatura para avaliação de modelos de detecção e segmentação [27], [28]. Vale salientar que no cálculo da AUC é feita na máscara não-binária, ou seja sem a aplicação do limiar. As Tabelas I e II apresentam os resultados obtidos. Na Tabela I os valores são agrupados com base na experiência em sensoriamento remoto, enquanto que na Tabela II os valores são agrupados com base na experiência com imagens SAR.

A Tabela III apresenta os valores de F1, IOU, AUC e Precisão para os resultados obtidos com a Unet. Comparando estes valores com os valores das Tabelas I e II, observa-se uma clara diferença de desempenho. Mais especificamente, o modelo de detecção baseado na UNet apresentou um desempenho superior ao obtido pelos participantes no experimento. Vale ressaltar que o desempenho dos participantes nessa tarefa foi baixo, conforme demonstrado pela AUC. Nesta métrica o resultado de 50% corresponde ao desempenho de um modelo aleatório. Em contrapartida, o modelo baseado na UNet apresentou AUC 67%, indicando um desempenho moderado na detecção de desmatamento.

Tabela I
MÉTRICAS F1, IOU, AUC E PRECISÃO, AGRUPADOS COM RELAÇÃO AO NÍVEL DE EXPERIÊNCIA DO PARTICIPANTE EM SENSORIAMENTO REMOTO.

Experiência em Sensoriamento Remoto	F1%	IOU%	AUC%	Precisão%
0	5.5	3.2	51.0	8.3
1	11.0	6.3	51.4	14.8
2	6.4	3.8	52.0	10.0
3	0.9	0.5	49.7	2.4
4	15.1	9.1	52.5	21.5

Tabela II
MÉTRICAS F1, IOU, ROC E PRECISÃO, AGRUPADAS DE ACORDO COM A EXPERIÊNCIA AUTODECLARADA DO PARTICIPANTE EM SAR.

Experiência em SAR	F1%	IOU%	AUC%	Precisão%
0	6.6	3.8	51.1	10.7
1	10.9	6.2	51.6	13.4
2	2.4	1.5	52.3	3.5
3	7.9	4.6	51.8	11.8

Tabela III
VALORES DAS MÉTRICAS F1, IOU, ROC E PRECISÃO PARA O MODELO DE DETECÇÃO DE ÁREAS DESMATADAS BASEADO NA UNET.

F1%	IOU%	AUC%	Precisão%
39.5	27.5	67.0	37.8

V. CONCLUSÕES

Este estudo investigou a relação entre o nível de experiência autodeclarada de indivíduos e a qualidade das anotações produzidas para áreas desmatadas em imagens SAR, bem como a capacidade de um sistema automático em detectar essas áreas. Os resultados sugerem uma baixa relação entre experiência autodeclarada e a qualidade de anotações, indicando que maior conhecimento em sensoriamento remoto e SAR não necessariamente leva a anotações de maior qualidade. Além disso, o estudo mostrou que a precisão de um modelo automático, baseado na UNet, para detecção de áreas desmatadas superou o obtido com participantes. Esses achados mostram o potencial para o uso de aprendizado profundo para a detecção de desmatamento. São necessários estudos para aprimorar o modelo automático, além de um melhor treinamento de especialistas para aperfeiçoar a qualidade das anotações.

REFERÊNCIAS

- [1] C. A. Nobre, G. Sampaio, and L. Salazar, "Mudanças climáticas e amazônia," *Ciência e Cultura*, vol. 59, no. 3, pp. 22–27, 2007.
- [2] I. C. G. Vieira, R. A. O. Santos Junior, and P. M. d. Toledo, "Dinâmicas produtivas, transformações no uso da terra e sustentabilidade na amazônia," *COCST*, 2014.
- [3] NASA. (2023) Landsat. [Online]. Available: https://www.nasa.gov/mission_pages/landsat/main/index.html
- [4] ESA. (2023) Sentinel-2 mission guide. [Online]. Available: <https://sentinel.esa.int/web/sentinel/missions/sentinel-2>
- [5] ——. (2023) Geoeye-1 mission guide. [Online]. Available: <https://earth.esa.int/eogateway/missions/geoeye-1>
- [6] ——. (2023) Sentinel-1 mission guide. [Online]. Available: <https://sentinels.copernicus.eu/web/sentinel/missions/sentinel-1>
- [7] ——. (2023) Twin satellites terrasat-x and tandem-x. [Online]. Available: <https://earth.esa.int/eogateway/news/twin-satellites-terrasat-x-and-tandem-x>
- [8] ——. (2023) Discover how radarsat scans earth's surface. [Online]. Available: <https://earth.esa.int/eogateway/news/discover-how-radarsat-scans-earths-surface>
- [9] Y. Zhou, P. Wang, Z. Chen, Q. Zhao, W. Wang, L. Zhang, W. Yu, and Y.-K. Deng, "Very-high-resolution sar imaging with dgps-supported airborne x-band data," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. PP, pp. 1–1, 06 2020.
- [10] D. Geudtner, R. Torres, P. Snoeij, M. Davidson, and B. Rommen, "Sentinel-1 system capabilities and applications," in *2014 IEEE Geoscience and Remote Sensing Symposium*, 2014, pp. 1457–1460.
- [11] N. Yagüe-Martínez, P. Prats-Iraola, F. R. Gonzalez, R. Brcic, R. Shau, D. Geudtner, M. Eineder, and R. Bamler, "Interferometric processing of sentinel-1 tops data," *IEEE transactions on geoscience and remote sensing*, vol. 54, no. 4, pp. 2220–2234, 2016.
- [12] A. Moreira, P. Prats-Iraola, M. Younis, G. Krieger, I. Hajnsek, and K. P. Papathanassiou, "A tutorial on synthetic aperture radar," *IEEE Geoscience and Remote Sensing Magazine*, vol. 1, no. 1, pp. 6–43, 2013.
- [13] G. A. Pimenta, F. B. J. R. Dallaqua, Á. L. Fazenda, and F. Faria, "Neuroevolution-based classifiers for deforestation detection in tropical forests," *2022 35th SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI)*, vol. 1, pp. 13–18, 2022.
- [14] W. Zhu, Y. Zhang, L. Qiu, and X. Fan, "Research on target detection of sar images based on deep learning," in *Image and Signal Processing for Remote Sensing XXIV*, vol. 10789. SPIE, 2018, pp. 581–588.
- [15] T. Zheng, J. Wang, and P. Lei, "Deep learning based target detection method with multi-features in sar imagery," in *2019 6th Asia-Pacific Conf. on Synthetic Aperture Radar (APSAR)*. IEEE, 2019, pp. 1–4.
- [16] O. Ronneberger, P. Fischer, and T. Brox, "U-net: Convolutional networks for biomedical image segmentation," *CoRR*, vol. abs/1505.04597, 2015. [Online]. Available: <http://arxiv.org/abs/1505.04597>
- [17] R. Ali, J. H. Chuah, M. S. A. Talip, N. Mokhtar, and M. A. Shoaib, "Structural crack detection using deep convolutional neural networks," *Automation in Construction*, vol. 133, p. 103989, 2022.
- [18] J. Jing, Z. Wang, M. Rättsch, and H. Zhang, "Mobile-unet: An efficient convolutional neural network for fabric defect detection," *Textile Research Journal*, vol. 92, no. 1-2, pp. 30–42, 2022.
- [19] D. John and C. Zhang, "An attention-based u-net for detecting deforestation within satellite sensor imagery," *International Journal of Applied Earth Observation and Geoinformation*, vol. 107, p. 102685, 2022.
- [20] B. S. et al., "opencv/cvat: v1.1.0." Aug. 2020. [Online]. Available: <https://doi.org/10.5281/zenodo.4009388>
- [21] ESA. (2023) About copernicus. [Online]. Available: <https://www.copernicus.eu/en/about-copernicus>
- [22] F. J. Ponzoni, M. A. H. Antunes, C. T. Pinto, R. A. C. Lamparelli, and J. Z. Junior, *Calibração de sensores orbitais*. Oficina de Textos, 2015.
- [23] H. Choi and J. Jeong, "Speckle noise reduction technique for sar images using statistical characteristics of speckle noise and discrete wavelet transform," *Remote Sensing*, vol. 11, no. 10, p. 1184, 2019.
- [24] P. A. Tavares, N. E. S. Beltrão, U. S. Guimarães, and A. C. Teodoro, "Integration of sentinel-1 and sentinel-2 for classification and lulc mapping in the urban area of belém, eastern brazilian amazon," *Sensors*, vol. 19, no. 5, p. 1140, 2019.
- [25] W. Wang, J. Dai, Z. Chen, Z. Huang, Z. Li, X. Zhu, X. Hu, T. Lu, L. Lu, H. Li, X. Wang, and Y. Qiao, "Internimage: Exploring large-scale vision foundation models with deformable convolutions," 2023.
- [26] J. McGlinchy, B. Johnson, B. Muller, M. Joseph, and J. Diaz, "Application of unet fully convolutional neural network to impervious surface segmentation in urban environment from high resolution satellite imagery," in *IGARSS 2019 - 2019 IEEE International Geoscience and Remote Sensing Symposium*, 2019, pp. 3915–3918.
- [27] Z. Shirvani, O. Abdi, and R. C. Goodman, "High-resolution semantic segmentation of woodland fires using residual attention unet and time series of sentinel-2," *Remote Sensing*, vol. 15, no. 5, 2023.
- [28] P. Tovar, M. Adarme, and R. Feitosa, "Deforestation detection in the amazon rainforest with spatial and channel attention mechanisms," *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. 43, pp. 851–858, 2021.