



# Confecção de algoritmo de detecção autônoma de embarcações em imagens orbitais de radar de abertura sintética (SAR)

Luis G. R. Vito<sup>1,2</sup>, Angelo Passaro<sup>3</sup>

<sup>1</sup>Instituto Tecnológico de Aeronáutica, São José dos Campos/SP – Brasil. <sup>2</sup>Centro de Guerra Eletrônica e Acústica da Marinha, Rio de Janeiro/RJ - Brasil.

<sup>3</sup>Instituto de Estudos Avançados, São José dos Campos/SP - Brasil

**Resumo** — Neste estudo, foi desenvolvido e apresentado um algoritmo inovador destinado à detecção autônoma de embarcações utilizando imagens SAR (Radar de Abertura Sintética). Para atingir essa finalidade, foram implementadas modificações na consagrada rede neural U-Net, além da integração de um código de índice de probabilidade, otimizando a segmentação e elevando a precisão da detecção subsequente. Ao submeter o algoritmo a testes em um conjunto selecionado de imagens SAR processadas, observou-se um desempenho notável, com índices de 78% de precisão, 99% de acurácia, 73% de F1-score, 68% de IoU, e uma impressionante probabilidade de detecção de embarcações excedendo 95%, superando algumas referências [1], [11]. Os resultados confirmam a eficácia do algoritmo, e também sua versatilidade em identificar embarcações de variadas dimensões, seja em águas calmas ou em cenários marítimos mais desafiadores. Os avanços tangíveis demonstrados neste estudo abrem caminho para expectativas otimistas quanto ao futuro da detecção marítima baseada em SAR. Além disso, os resultados apontam para a possibilidade real de se ter um sistema de monitoramento marítimo mais eficiente, de resposta ágil, e que, simultaneamente, requer menos recursos computacionais, tornando-o uma ferramenta valiosa para aplicações práticas em gestão e segurança marítima.

## I. INTRODUÇÃO

As imagens de radar de abertura sintética (SAR), adquiridas por sensores em aeronaves ou satélites, são ideais para monitoramento marítimo devido à sua capacidade de fornecer imagens de alta resolução independentemente das condições climáticas e luminosidade [1]. Essas imagens são sensíveis às propriedades de retrospalhamento da superfície do mar, facilitando a identificação de características oceânicas. Com o aumento do tráfego marítimo global, a necessidade de monitoramento eficaz tornou-se imperativa. A tecnologia SAR, em particular, tem sido fundamental para a detecção precisa de embarcações, derramamentos de óleo e outros alvos marítimos, especialmente em situações de emergência. No entanto, a automatização desse monitoramento é um desafio [2]. Enquanto os algoritmos iniciais, como o Constant False Alarm Rate (CFAR) [3], ofereciam resultados consistentes [4], eles eram limitados em sua capacidade de distinguir entre embarcações e outras interferências. O advento do aprendizado profundo trouxe avanços significativos na detecção de embarcações em imagens SAR [5], [6], [7]. As redes neurais convolucionais (CNNs) são capazes de aprender características das imagens, melhorando a precisão na detecção de objetos. No entanto, desafios persistem devido à complexidade das imagens SAR e interferências naturais. Este trabalho visa aprimorar a detecção de embarcações em imagens SAR utilizando aprendizado profundo, especificamente a arquitetura U-Net, com o objetivo de desenvolver um algoritmo mais eficiente e robusto.

## II. MATERIAIS E MÉTODO

A U-Net, proposta por Ronneberger et al. [8], é uma arquitetura de rede neural convolucional desenvolvida inicialmente para segmentação de imagens biomédicas. Sua estrutura em forma de "U", como pode ser observado na Figura 1 e suas conexões de salto (*skip connections*) tornam-na eficaz para segmentação de imagens, sendo adaptada para detecção de alvos em imagens SAR, incluindo embarcações e manchas de óleo [9], [10].



Fig. 1. Arquitetura da rede U-Net Original [8].

Este trabalho empregou uma versão adaptada da arquitetura U-Net. As adaptações realizadas foram a substituição das camadas convolucionais por blocos residuais, a inclusão de camadas *dropout* para aprimorar a eficácia e mitigar o *overfitting*, além da aplicação de regularização L1 ou L2 nos pesos da rede. Essas modificações têm como propósito otimizar a capacidade da rede em lidar com a complexidade dos dados SAR. A Tabela I apresenta os principais parâmetros da arquitetura aprimorada.

TABELA I – HIPERPARAMETROS DA U-NET MODIFICADA

Hiperparâmetro	Valor
Número de Épocas	100
Tamanho do Lote ( <i>batch size</i> )	4
Taxa de Aprendizagem	0.0000005
Transformações de Dados	Horizontal, Vertical, Redimensionamento (256, 256)
Arquitetura da Rede	UNet
Função de Perda	Binary Cross Entropy
Otimizador	Adam

O treinamento utilizou um *dataset* fornecido por Krestenitis [11], composto por 1.112 imagens SAR do Satélite Sentinel-1 com presença de embarcações e manchas de óleo devidamente rotuladas. Os processamentos e treinamentos foram realizados em dois computadores dotados de GPU (*Graphics Processing Unit*). O modelo foi avaliado usando métricas como precisão, acurácia, *F1-score* e *IoU*. Além disso, índices de probabilidade foram implementados para aprimorar a detecção e auxiliar na determinação da presença dos alvos.

## II. RESULTADOS

O algoritmo desenvolvido para detecção autônoma de embarcações em imagens SAR mostrou-se eficaz, identificando embarcações sob diversas condições ambientais. As métricas obtidas foram: precisão de 78%, acurácia de 99%, *F1-score* de 73% e *IoU* de 68%, superando algumas referências [1], [11]. A Figura 2 ilustra uma imagem SAR original (esquerda) e os rótulos da verdade de campo localizando as embarcações, que foram utilizados nos treinamentos. Na Figura 3 é um exemplo da predição realizada com o algoritmo treinado. Pode-se observar que os resultados obtidos da predição são muito próximos com a verdade de campo, comprovando a eficiência e resultados alcançados pelo algoritmo.

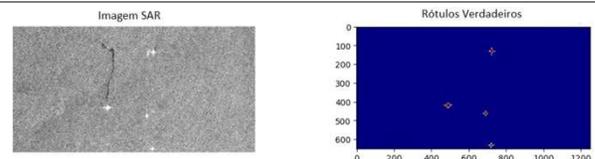


Fig. 2. Imagem SAR original (esquerda) e rótulos (máscaras) das embarcações utilizados nos treinamentos (direita). Azul é o fundo e em vermelho as embarcações.

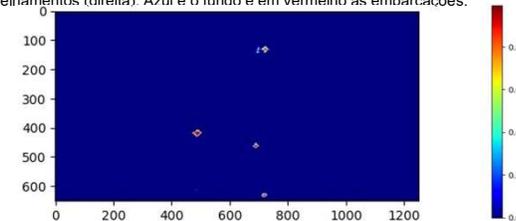


Fig. 3. Resultados da detecção (predição) com escala de probabilidade. Nota-se que os resultados alcançaram praticamente o valor máximo de acerto na escala (vermelho escuro).

## III. CONCLUSÃO

Este estudo confeccionou um algoritmo voltado para a detecção autônoma de embarcações em imagens SAR, fazendo uso de uma adaptação da arquitetura U-Net, complementada pela aplicação de índices de probabilidade.

Os dados colhidos ressaltam que o método sugerido tem a capacidade de identificar embarcações em imagens SAR de maneira eficiente, superando até mesmo benchmarks estabelecidos em termos de precisão e rapidez [1], [11].

Apesar dos avanços observados, a identificação de embarcações através de imagens SAR ainda se depara com obstáculos relevantes. Um dos maiores entraves é a diversidade inerente das imagens, amplificada pelas interferências ambientais e pela variedade de dispositivos disponíveis no mercado.

Outro ponto a ser considerado é que cada sensor SAR possui especificidades - seja em banda de frequência, resolução, ângulo de incidência, entre outros. Essa diversidade sugere que, em diversas situações, é imperativo contar com uma vasta quantidade de dados etiquetados para o treino adequado de um modelo, ou mesmo conceber um algoritmo personalizado para determinado dispositivo.

Portanto, essas questões reforçam a importância de estudos contínuos para aprimorar as técnicas de identificação de embarcações em imagens SAR. Ao enfrentar e superar tais desafios, será possível ampliar a precisão e a confiabilidade nesta área, crucial para a supervisão e administração marítima.

## REFERÊNCIAS

- [1] Y. Mao, Y. Yang, Z. Ma, M. Li, H. Su, and J. Zhang, "Efficient low-cost ship detection for sar imagery based on simplified u-net," *IEEE Access*, vol. 8, pp. 69 742–69 753, 2020.
- [2] J. Clerk Maxwell, "A Treatise on Electricity and Magnetism", 3ed., vol. 2. Oxford: Clarendon, 1892, p.68–73.
- [3] O. Ronneberger, P. Fischer, and T. Brox, "U-net: Convolutional networks for biomedical image segmentation," in *International Conference on Medical Image Computing and Computer-Assisted Intervention*. Springer, Cham, 2015, pp. 234–241, pp. 1–9.
- [4] J. Li, C. Guo, S. Gou, Y. Chen, M. Wang, and J.-W. Chen, "Ship segmentation on high-resolution sar image by a 3d dilated multiscale unet," in *IGARSS 2020-2020 IEEE International Geoscience and Remote Sensing Symposium*. IEEE, 2020, pp. 2575–2578.
- [5] J. Chen, X. Xu, J. Zhang, G. Xu, Y. Zhu, B. Liang, and D. Yang, "Ship target detection algorithm based on decision-level fusion of visible and sar images," *IEEE Journal on Miniaturization for Air and Space Systems*, 2023.
- [6] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," *arXiv preprint arXiv:1409.1556*, 2014.
- [7] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, and A. Rabinovich, "Going deeper with convolutions," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2015.
- [8] M. Skolnik, *Radar Handbook*. McGraw Hill, 2008.
- [9] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks," *Communications of the ACM*, vol. 60, no. 6, pp. 84–90, 2017.
- [10] M. Krestenitis, G. Orfanidis, K. Ioannidis, K. Avgerinakis, S. Vrochidis, and I. Kompatsiaris, "Oil spill identification from satellite images using deep neural networks," *Remote Sensing*, vol. 11, no. 15, p. 1762, 2019.