

Avaliação de Algoritmos de Machine Learning na Classificação de Alvos Marítimos em Imagens SAR

Fabiano G. da Silva^{1,3}, Lucas P. Ramos¹, Bruna G. Palm² e Renato Machado¹

¹Instituto Tecnológico de Aeronáutica (ITA), São José dos Campos/SP – Brasil

²Blekinge Institute of Technology (BTH), Karlskrona - Sweden

³Centro de Guerra Acústica e Eletrônica da Marinha (CGAEM), Niterói/RJ - Brasil

Resumo-Recentemente, a disponibilidade de dados públicos de sensoriamento remoto obtidos através de sistemas orbitais têm aumentado significativamente, tornando possível a avaliação de técnicas de inteligência artificial para obtenção de diversos produtos, como detecção, discriminação e classificação de alvos. Este artigo avalia os algoritmos de machine learning (ML) para classificar alvos (plataformas petrolíferas e navios) em imagens polarimétricas VH de radar de abertura sintética (SAR), obtidas pelo sistema Sentinel-1 operando na banda C. Para isso, os algoritmos random forest (RF) e k-nearest-neighbors (kNN) disponíveis nas bibliotecas Python de ML, Orange e Scikit-learn, são considerados. Estes algoritmos operam através de atributos gerados pela rede neural convolucional (CNN, convolutional neural network) VGG-16. Como métricas de avaliação, utilizamse a acurácia e a área abaixo da curva. Os maiores resultados são obtidos com a biblioteca Orange e se mostram competitivos com os alcancados na literatura.

Palavras-Chave-kNN, Machine Learning, Random Forest.

I. INTRODUÇÃO

As imagens orbitais têm sido utilizadas no sensoriamento remoto da terra para mapeamento de mudanças climáticas, queimadas florestais, poluição de águas e do ar [1]. Dentre os sistemas orbitais, destaca-se o radar de abertura sintética (SAR, *synthetic aperture radar*). Por ser um sensor ativo, este sistema é capaz de imagear grandes áreas e gerar imagens durante o dia e noite com alta resolução espacial. As nuvens não interferem no processo de aquisição de dados pelo sensor, assim como as condições climáticas adversas pouco influenciam na geração das imagens [2].

O radar emite pulsos de onda eletromagnética com alta potência e recebe o eco do sinal retroespalhado. Apenas uma parte dessa onda transmitida é recebida pelo sensor da antena do radar [2]. Em particular, o processo de formação da imagem SAR é devido ao retroespalhamento da onda eletromagnética ao antigir um alvo. Esse fenômeno também é conhecido como *backscatterred*. A amplitude e fase do sinal retroespalhado dependem das características físicas do material (e.g., geometria e rugosidade) e das propriedades dielétricas [2]. Devido ao processo de multipercursos, as imagens SAR são afetadas pelo efeito *speckle* ou ruído multiplicativo. Além disso, essas imagens são caraterizadas por possuir maior brilho nas áreas com mais retroespalhamento. Os dados orbitais SAR podem ser usadas em diversas aplicações, e.g., detecção de navios [3], classificação de plataformas de petróleo [4], mapeamento urbano [5], caracterização de solos [6], mapeamento vulcânico [7], vigilância maritima [8], [9], e detecção de manchas de óleo no mar [10]. Dentre os sistemas SAR considerados em diferentes aplicações, destacam-se: [2]: o europeu Sentinel-1; os alemães TERRASAR-X e TANDEM-X; os chineses HJ-1C e GAOFEN-3; o italiano COSMO-SkyMed; o japones ALOS 2; o indiano RISAT-1; o canadense Radarsat-1/2; o argentino SAOCOM-1/2; o espanhol PAZ.

O Brasil possui uma extensa área marítima conhecida como "Amazônia Azul" que é rica em biodiversidade, recursos naturais, como por exemplo, o petróleo [11], na qual foi descoberto o pré-sal [12]. Diante disso, há necessidade de monitorar e controlar essa faixa do litoral, sendo o SAR uma alternativa interessante por gerar imagens de alta resolução e com informações de amplitude e fase que permitem uma análise mais detalhada dos alvos de interesse.

Nas aplicações de classificação de alvos marítimos, técnicas de *machine learning* (ML) e *deep learning* (DL) têm sido amplamente consideradas [13], [14], [15] Algumas dessas técnicas são: *support vector machine* (SVM) [16], *random forest* (RF) [17], *logistic regression*, *k*-nearest-neighbors (kNN) [17], redes neurais [18]. As redes neurais convolucionais (CNN, *convolutional neural network*) também são ferramentas interessantes para classificação e extração de atributos.

Neste artigo, avaliam-se os algoritmos kNN e RF, disponíveis nas bibliotecas *Orange* e *Scikit-Learn*, para classificação de alvos marítimos em imagens SAR. Como dados, utilizam-se imagens SAR, polarização VH, obtidas pelo sistema Sentinel-1 operando na banda C. Para extrair os atributos das imagens, a CNN VGG-16 pré-treinada com o banco de dados *imagenet* foi considerada [19], [20]. Além desta introdução, a Seção II apresenta os Materiais e Métodos; a Seção III apresenta os Resultados e Discussões. Por fim, a Seção IV conclui este trabalho de pesquisa.

II. MATERIAIS E MÉTODOS

Esta seção apresenta o banco de dados considerado, as técnicas de ML utilizadas pelos softwares de código aberto *Orange* [21] e *Scikit-Learn* [22]. Além disso, também são explicadas todas as etapas da metodologia aplicada neste artigo.

A. Imagens SAR

Considerou-se o sistema Sentinel-1 neste estudo. Esse sistema possui as seguintes características: banda C; frequência

Fabiano G. da Silva, fabianogabriel@gmail.com; Lucas P. Ramos, lucaspr@ieee.org; Bruna G. Palm, bruna.palm@bth.se, Renato Machado, renatomachado@ieee.org. Este trabalho foi parcialmente financiado pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), Código de Financiamento 001 (Pró-Defesa IV), Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq). Os autores também agradecem ao *Brazilian Institute of Data Science* (BIOS), outorga 2020/09838 -0.



5,405 GHz e polarização HH+HV,VV+VH,VV, HH [8]. A base das imagens é o produto ground range detected (GRD), modo interferometric wide swarth (IW), high resolution (20 m \times 22 m - range \times azimuth). A Fig. 1 apresenta uma comparação entre as imagens ópticas [23] e os patches das imagens SAR [24] das plataformas de petróleo do tipo Floating Storage and Offloading (FSO) P-38, Floating Production Storage and Offloading (FPSO) P-58 e Floating and Production Unit (FPU) P-53.



Fig. 1. Comparação entre imagens óptica e SAR de plataformas de petróleo. Imagens ópticas e SAR extraídas de [23] e [24], respectivamente.

B. Bibliotecas Open Source e algoritmos de classificação

Para classificação dos alvos, utilizam-se os classificadores kNN e RF disponíveis nas bibliotecas de código aberto (*open source*) Orange [25] e Scikit-learn [22] que são desenvolvidas em Python e realizam tarefas de ML, data mining e visualização de dados. Essas ferramentas estão cada vez mais sendo utilizadas pela comunidade científica [26], [4].

A seguir elencam-se as vantagens e desvantagens das bibliotecas *Scikit-Learn* [27] e *Orange* [28] e dos classificadores kNN [29] e RF [29].

i. Scikit-learn

- Vantagens:
 - Possui documentação atualizada e com códigos de exemplos;
 - Abrange a maioria dos algoritmos de ML;
 - Possui fluxograma que orienta o usuário na seleção do modelo.
- Desvantagens:
 - Não é uma plataforma analítica de ponta a ponta. Sendo assim, pode ser necessário a integração com outras soluções;
 - Possui alta curva de aprendizado;
 - Não lida de forma simples com grande quantidade de dados.

ii. Orange

- Vantagens:
 - Inclui as funções para data mining, machine learning, preprocessamento e visualização de dados;
 - Programação visual, representada através de *wid-gets*, de fácil aprendizagem e com código desenvolvido em *Python*;
 - Permite Operações com *big data* utilizando o *widget* SQL, mas é necessário instalar o módulo *psycopg2*;
 - Constante desenvolvimento e atualização de widgets;
 - Documentação online ampla com exemplos e tutoriais.
- Desvantagens:
 - Número limitado de *widgets* quando comparado com outros softwares como *RapideMiner* [30] e *KNIME* [31];
 - Suporte apenas aos bancos de dados *PostgreSQL* e *MSSQL*.

iii. RF

- Vantagens:
 - Uso em classificação e regressão com dados numéricos e categóricos;
 - Modela relações de dados não lineares;
 - Resistência a *overfitting* e robustez a presença de ruído nos dados;
 - O aumento do número de árvores, diminui a variância;
 - Utiliza aleatoriedade na formação dos subgrupos de árvores de decisão independentes;
 - Cada árvore de decisão produz resultados independentes;
 - Não tendencioso porque a decisão final depende de todos os resultados.
- Desvantagens:
 - Não há um número exato de árvores para obter-se o melhor resultado de classificação, já que o tamanho dos dados e quantidade de atributos influenciam nos resultados;
 - Aumento do número de árvores, aumenta o viés;
 - Maior tempo de processamento e maior complexidade de algoritmo quando comparado com árvores individuais.

iv. kNN

- Vantagens:
 - Lógica simples e fácil configuração para problemas mais complicados;
 - Aumento do k, diminui a variância;
 - Há uma Variedade de técnicas para cálculo eficiente da distância de k-vizinhos mais próximos;
 - Aplicações em classes multimodais e com muitos rótulos.
- Desvantagens:
 - Pode consumir mais memória para um grande número de atributos;
 - Aumento do custo computacional para grande cunjuntos de dados devido à necessidade de cálculo



da distância do objeto não rotulado para os objetos rotulados;

- Aumento de k, aumenta o viés;
- Uso de comparações baseadas em distância que atribuem intrinsecamente peso igual a cada atributo Deve-se escolher uma técnica que incorpore ponderação de atributos.

C. Metodologia

Neste estudo utilizam-se imagens SAR orbitais, técnicas de DL para extração de atributos e técnicas de ML para classificação. A metodologia é apresentada na Fig. 2 e explicada com detalhes no itens a seguir.



Fig. 2. Metodologia considerada neste estudo.

- Imagens SAR: são adquiridas 8 imagens SAR, modo GRD, IW, L1, polarização VH, através do projeto Copernicus [32];
- 2) Pré-Processamento: as imagens SAR originais do tipo amplitude são transformadas em imagens sigma zero através do software Sentinel Application Platform (SNAP). A partir dessas imagens são coletados 400 patches dos alvos no formato Tagged Image File Format (TIFF), sendo 200 de plataformas de petróleo e 200 de navios. A verdade de campo (ground truth) das plataformas de petróleo é obtida com base na geolocalização (latitude × longitude) fornecida pela Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (ANP) e do portal Marine Traffic [33];
- Extração de atributos: a extração de atributos é realizada através da vetorização dos 400 *patches* de imagens utilizando a VGG-16 pré-treinada com o banco de dados *ImageNet*;
- Formação do banco de dados: com base nos atributos extraídos pela VGG-16, forma-se o *dataframe* df-16vh;
- 5) *Bootstrap* e formação de grupos de treino e teste: com base no *dataframe* original, df-16vh, que é composto por 400 amostras (*patches*) dos alvos, e seguindo a

mesma metodologia proposta por [24], formam-se 50 subgrupos distintos de forma aleatória e com resposição através da técnica *bootstrap*. Cada grupo é formado por amostras de treino (80% do total de amostras) e teste (20% do total de amostras);

- 6) Classificação: a classificação dos alvos é efetuada com os classificadores de ML RF e kNN das bibliotecas *Python, Orange* e *Scikit-learn*. O ajuste dos parâmetros é feito da seguinte forma: RF - número de árvores: 50; kNN - número de vizinhos: 7. Para comparação, as seguintes métrica foram empregadas [34].
 - Área abaixo da curva (AUC, area under the curve): esta métrica é formada pela área abaixo da curva (ROC, Receiver Operating Characteristic). A AUC resume o valor da curva ROC em um número que varia entre 0 e 1. Quanto mais próximo de 1, melhor a performance.
 - Acurácia (Acc, *accuracy*): esta métrica indica a proporção de amostras corretamente classificadas, diante do total de amostras em um teste.

III. RESULTADOS E DISCUSSÕES

A Tabela I apresenta os resultados da média das métricas em 50 classificações dos subgrupos gerados com a técnica *bootstrap*. Percebe-se que o RF possui os maiores valores de AUC e Acc, destacando os resultados com a biblioteca *Orange* que apresenta 0,905 e 0,818, para AUC e Acc, respectivamente. Comparando o RF das duas bibliotecas, a AUC possui os mesmos valores, 0,905. Analisando a Tabela I, a mediana é a mesma para o RF com as duas bibliotecas, 0,812. Já em relação ao kNN, o maior desvio padrão é de 0,039 com o *Scikit-Learn*.

TABELA I DADOS ESTATÍSTICOS DOS CLASSIFICADORES ANALISADOS.

	RF		kNN	
Classificador	Orange	SkLearn	Orange	SkLearn
Grupos teste e treino	50	50	50	50
AUC	0,905	0,905	0,865	0,862
Acc	0,818	0,812	0,792	0,774
Desvio Padrão	0,041	0,045	0,036	0,039
Mediana	0,812	0,812	0,788	0,775
Valor mínimo	0,750	0,712	0,725	0,688
Valor máximo	0,950	0,900	0,862	0,850
Distância interquartil	0,050	0,063	0,047	0,059

A Fig. 3 apresenta o histograma de distribuição com as médias de classificações. Com base na dispersão dos dados, também apresenta-se no mesmo gráfico a distribuição de probabilidade. O histograma do RF com a biblioteca *Orange* tem a maior concentração de acurácia entre 0,775 e 0,850. Ainda de acordo com a Fig. 3, os resultados com *Orange* são mais concentrados para os dois classificadores enquanto que os resultados com o *Scikit-learn* apresentaram-se espalhados. Ao analisar os boxplot da Fig. 4, evidenciam-se os resultados com o *Orange* como melhores que os resultados do *Scikit-learn*. As médias no *Orange* são superiores as medianas. As médias de acurácia apresentadas pelo *Orange* possuem maior homogeneidade, conforme pode ser visto pela forma da caixa do boxplot, ou seja, a distância da mediana para o primeiro e



terceiro quartil possuem valores aproximados. Os resultados obtidos se mostram competitivos com [24].

De acordo com a biblioteca de ML utilizada, um mesmo algoritmo pode apresentar resultados diferentes. Isso pode ocorrer devido a diversos fatores. dentre eles:

- funções de pré-processamento;
- arredondamentos;
- ajuste de parâmetros disponíveis;
- bibliotecas científicas utilizadas na implementação (*Numpy, Scipy, Scikit-learn, PyTorch*).



Fig. 3. Histograma de distibuição de acurácia entre os classificadores RF e kNN considerando as bibliotecas *Orange* e *Scikit-Learn*.



Fig. 4. Comparação entre classificadores RF e kNN considerando as bibliotecas *Orange* e *Scikit-Learn*.

IV. CONCLUSÕES

Este artigo avaliou os algoritmos de ML RF e kNN com as bibliotecas *Orange* e *Scikit-learn* na classificação de alvos marítimos. Devido a suas grandes estruturas metálicas e geometria, os navios e plataformas se destacam no canal de polarização VH gerando maior *backscattered*. A CNN VGG-16 se mostrou eficiente para extração de atributos das imagens SAR e geração de vetores para ambos os classificadores com as duas bibliotecas. O RF da biblioteca *Orange* obteve melhor desempenho com acurácia de 81,8% e AUC de 0,905. Os classificadores da biblioteca *Scikit-learn* apresentaram acurácia de 81,2% e 77,4% para o RF e kNN, respectivamente. Os resultados obtidos nesta pequisa se mostram competitivos com a literatura. Como trabalhos futuros, pode-se avaliar o algoritmo *Gradient Boosting* para classificação e outras opções de CNN, como por exemplo a *SqueezeNet*, para extração de atributos.

V. AGRADECIMENTOS

O presente artigo foi realizado com apoio do Laboratório de Guerra Eletrônica (LabGE), ITA.

Referências

- R. Garg, A. Kumar, M. Prateek, K. Pandey, and S. Kumar, "Land cover classification of spaceborne multifrequency sar and optical multispectral data using machine learning," *Advances in Space Research*, vol. 69, no. 4, pp. 1726–1742, 2022.
- [2] A. Moreira, P. Prats-Iraola, M. Younis, G. Krieger, I. Hajnsek et al., "A tutorial on synthetic aperture radar," *IEEE Geoscience and remote sensing magazine*, vol. 1, no. 1, pp. 6–43, 2013.
- [3] A. Grover, S. Kumar, and A. Kumar, "Ship detection using sentinel-1 sar data." *ISPRS Annals of Photogrammetry, Remote Sensing & Spatial Information Sciences*, vol. 4, no. 5, 2018.
- [4] F. G. da Silva, L. P. Ramos, B. G. Palm, and R. Machado, "Assessment of Machine Learning Techniques for Oil Rig Classification in C-Band SAR Images," *Remote Sensing*, vol. 14, no. 13, 2022. [Online]. Available: https://www.mdpi.com/2072-4292/14/13/2966
- [5] B. P. ME and S. Kumar, "Multifrequency analysis of polinsar-based decomposition using cosine-squared distribution," *IETE Technical Review*, pp. 1–8, 2021.
- [6] A. Singh, K. Gaurav, G. K. Meena, and S. Kumar, "Estimation of soil moisture applying modified dubois model to sentinel-1; a regional study from central india," *Remote Sensing*, vol. 12, no. 14, p. 2266, 2020.
- [7] A. Babu and S. Kumar, "Sbas interferometric analysis for volcanic eruption of hawaii island," *Journal of Volcanology and Geothermal Research*, vol. 370, pp. 31–50, 2019.
- [8] R. Torres, P. Snoeij, D. Geudtner, D. Bibby, M. Davidson *et al.*, "Gmes sentinel-1 mission," *Remote sensing of environment*, vol. 120, pp. 9–24, 2012.
- [9] L. Huang, B. Liu, B. Li, W. Guo, W. Yu et al., "Opensarship: A dataset dedicated to sentinel-1 ship interpretation," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 11, no. 1, pp. 195–208, 2018.
- [10] L. Xu, J. Li, and A. Brenning, "A comparative study of different classification techniques for marine oil spill identification using radarsat-1 imagery," *Remote Sensing of Environment*, vol. 141, pp. 14–23, 2014.
- [11] A. N. de Petroleo. (2021) Boletim mensal da produção de petróleo e gás natural. [Online]. Available: https://www.gov.br/anp/ptbr/centrais-de-conteudo/publicacoes/boletins-anp/boletins/arquivosbmppgn/2022/boletim-maio.pdf (Acesso em 18JUL2022)
- [12] M. de Oliveira Soares, T. M. da Cruz Lotufo, L. M. Vieira, S. Salani, E. Hadju et al., Brazilian marine animal forests: A new world to discover in the southwestern Atlantic. Cham, Switzerland: Springer International Publishing, 2017, pp. 73–110.
- [13] Y. Mao, X. Li, H. Su, Y. Zhou, and J. Li, "Ship detection for SAR imagery based on deep learning: A benchmark," in 2020 IEEE 9th Joint International Information Technology and Artificial Intelligence Conference (ITAIC), vol. 9. IEEE, 2020, pp. 1934–1940.
- [14] J. Kun and C. Yan, "Sar image ship detection based on deep learning," in 2020 International Conference on Computer Engineering and Intelligent Control (ICCEIC). IEEE, 2020, pp. 55–59.
- [15] F. Xu, H. Wang, Q. Song, W. Ao, Y. Shi, et al., "Intelligent Ship Recongnition from Synthetic Aperture Radar Images," in *IGARSS 2018-2018 IEEE International Geoscience and Remote Sensing Symposium*. IEEE, 2018, pp. 4387–4390.
- [16] F. Gao, T. Huang, J. Sun, J. Wang, A. Hussain *et al.*, "A new algorithm for SAR image target recognition based on an improved deep convolutional neural network," *Cognitive Computation*, vol. 11, no. 6, pp. 809–824, 2019.
- [17] A. Lapini, S. Pettinato, E. Santi, S. Paloscia, G. Fontanelli *et al.*, "Comparison of machine learning methods applied to sar images for forest classification in mediterranean areas," *Remote Sensing*, vol. 12, no. 3, p. 369, 2020.
- [18] Z. Xu, J. Sun, and Y. Huo, "Ship images detection and classification based on convolutional neural network with multiple feature regions," *IET Signal Processing*, 2022.
- [19] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks," *Advances in neural information processing systems*, vol. 25, 2012.
- [20] O. Russakovsky, J. Deng, H. Su, J. Krause, S. Satheesh *et al.*, "ImageNet Large Scale Visual Recognition Challenge," *International Journal of Computer Vision (IJCV)*, vol. 115, no. 3, pp. 211–252, 2015.
 [21] J. Demšar, T. Curk, A. Erjavec, Crt Gorup, T. Hočevar *et al.*, "Letter the set of the
- [21] J. Demšar, T. Curk, A. Erjavec, Črt Gorup, T. Hočevar et al., "Orange: Data Mining Toolbox in Python," *Journal of Machine Learning Research*, vol. 14, pp. 2349–2353, 2013. [Online]. Available: http://jmlr.org/papers/v14/demsar13a.html (Acesso em 18JUL2022)



- [22] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion et al., "Scikit-learn: Machine learning in Python," *Journal of Machine Learning Research*, vol. 12, pp. 2825–2830, 2011.
- [23] M. do Brasil, "Diretoria de Portos e Costas DPC," 2022. [Online]. Available: https://www.marinha.mil.br/dpc/helideques (Acesso em 16JUL2022)
- [24] L. E. Falqueto, J. A. Sá, R. L. Paes, and A. Passaro, "Oil Rig Recognition Using Convolutional Neural Network on Sentinel-1 SAR Images," *IEEE Geoscience and Remote Sensing Letters*, vol. 16, no. 8, pp. 1329–1333, 2019.
- [25] A. Jovic, K. Brkic, and N. Bogunovic, "An overview of free software tools for general data mining," in 2014 37th International convention on information and communication technology, electronics and microelectronics (MIPRO). IEEE, 2014, pp. 1112–1117.
- [26] P. Godec, M. Pančur, N. Ilenič, A. Čopar, M. Stražar *et al.*, "Democratized image analytics by visual programming through integration of deep models and small-scale machine learning," *Nature communications*, vol. 10, no. 1, pp. 1–7, 2019.
- [27] J. Santos-Pereira, L. Gruenwald, and J. Bernardino, "Top data mining tools for the healthcare industry," *Journal of King Saud University-Computer and Information Sciences*, 2021.
- [28] A. H. Altalhi, J. M. Luna, M. Vallejo, and S. Ventura, "Evaluation and comparison of open source software suites for data mining and knowledge discovery," *Wiley Interdisciplinary Reviews: Data Mining* and Knowledge Discovery, vol. 7, no. 3, p. e1204, 2017.
- [29] C. C. Aggarwal et al., Data mining: the textbook. Springer, 2015, vol. 1.
- [30] M. Hofmann and R. Klinkenberg, RapidMiner: Data mining use cases and business analytics applications. CRC Press, 2016.
- [31] M. Berthold, N. Cebron, F. Dill, T. Gabriel, T. Kötter *et al.*, "KNIME: the Konstanz information miner In Data analysis, machine learning and applications SE-38, Preisach C, Burkhardt H, Schmidt-Thieme L, Decker R," 2008.
- [32] ESA. (2021) Copernicus Open Access Hub. [Online]. Available: https://scihub.copernicus.eu/dhus/ (Acesso em 30JUN2022)
- [33] MarineTraffic. (2021) MarineTraffic Global Ship Tracking Intelligence. [Online]. Available: https://www.marinetraffic.com (Acesso em 30JUN2022)
- [34] D. Cantorna, C. Dafonte, A. Iglesias, and B. Arcay, "Oil spill segmentation in sar images using convolutional neural networks. a comparative analysis with clustering and logistic regression algorithms," *Applied Soft Computing*, vol. 84, p. 105716, 2019.