

kNN e Rede Neural Convolutacional para o Reconhecimento de Plataformas de Petróleo em Imagens SAR do Sentinel-1

Leonan Entringer Falqueto¹, Ricardo Suterio², Rafael Lemos Paes³ e Angelo Passaro³

¹Instituto de Aplicações Operacionais (IAOp), São José dos Campos/SP – Brasil

²Instituto Tecnológico de Aeronáutica (ITA), São José dos Campos/SP – Brasil

³Instituto de Estudos Avançados (IEAv), São José dos Campos/SP – Brasil

Resumo – O reconhecimento automático de alvos (plataformas petrolíferas) por meio de imagens de radar de abertura sintética (SAR) de média resolução auxilia a vigilância de áreas extensas como o Atlântico Sul. Esse trabalho aprofundou o estudo do emprego da VGG-16 como extratora de atributos para alimentar algoritmos de *Machine Learning*, especificamente, o kNN. Variou-se o número de vizinhos para um conjunto de amostras de imagens SAR do Sentinel-1 contendo plataformas marítimas e falsos-alarmes, usando um experimento com 50 blocos de treinamento e teste. Demonstrou-se que o ajuste de parâmetros do classificador apresenta melhorias significativas, com um incremento de 6,46% no indicador AUC.

Palavras-Chave – *Synthetic Aperture Radar* (SAR), Reconhecimento Automático de Alvos (ATR), *Machine Learning*.

I. INTRODUÇÃO

O Brasil, assim como os demais países com grandes dimensões territoriais, enfrenta o desafio de manter a vigilância sobre extensas áreas. Essa tarefa é sintetizada no conceito da Dimensão 22, veiculado pela Força Aérea Brasileira [1].

Os satélites imageadores proporcionam, rotineiramente, uma grande massa de dados distribuídas, inclusive, gratuitamente. Tais dados, se bem utilizados, podem contribuir para solucionar a questão da vigilância. Dentre esses sensores, destaca-se os satélites com SAR, que produzem amplas faixas de imageamento, operam diuturnamente e utilizam a banda espectral das micro-ondas, pouco afetada pelas condições meteorológicas da troposfera (atenuação do sinal por absorção de energia eletromagnética). Diversas constelações estão em operação nas principais bandas (X, C e L) e com diversas configurações, em termos de resolução e de polarização. Na verdade, a abundância de dados alçou o SAR à era do *Big Data* [2], [3].

A média de dados diária do Sentinel-1 (satélites SAR do Projeto Copernicus da ESA – *European Space Agency*), obtida no mês de novembro de 2017 foi de 3,79 Tb [3], [4]. A tendência é que essa a quantidade de dados aumente consideravelmente com a operação do Projeto NISAR, com a previsão de 85 Tb/dia [5]. Portanto, há uma necessidade premente de automatização no processo de vigilância por imagens orbitais, ou seja, são necessários métodos eficientes

para tratar e sintetizar essa quantidade dados em informações de apoio aos processos decisórios.

Dentre os alvos artificiais de interesse no oceano, a literatura é vasta para manchas de óleo e navios, porém pouco foi relatado sobre plataformas marítimas [6], [7]. Estudar a interação da onda eletromagnética com as plataformas marítimas tem relevância para as áreas de inteligência militar e econômica, para segurança da navegação naval e aérea de baixa altitude, para antecipação de providências em casos de desastres ambientais provocados por acidentes ou fenômenos naturais como furacões e para vigilância em casos de poluição ambiental. Além disso, uma das principais motivações é que a verdade de campo é obtida facilmente, por ser um alvo metálico parado e, normalmente, de posição conhecida. Isso facilita a extrapolação do conhecimento para outros objetos de interesse como navios, sobre os quais não é tão simples obter a verdade de campo. O desafio para reconhecimento de plataformas petrolíferas é a dinamicidade do ambiente marítimo associada à presença de muitos alvos semelhantes, enquanto elas apresentam características geométricas diversas, não apresentando um comportamento tão homogêneo quanto ao retroespalhamento do sinal radar [6]–[8].

No âmbito das técnicas de reconhecimento automático de alvos por meio de *deep learning*, as Redes Neurais por Convulsão (CNN) apresentam resultados promissores com imagens SAR de média e alta resolução. Uma taxa de acurácia de 79% foi alcançada para o reconhecimento de três tipos de navios (graneleiro, contêiner e petroleiro) usando imagens de média resolução Sentinel-1 (5m x 20m, SLC) [9].

O estado da arte no reconhecimento de alvos foi alcançado por meio de avanços na aprendizagem profunda [10]–[16], incentivando novos estudos em vigilância marítima com imagens coletadas pelos sensores espaciais atuais. Por exemplo, a CNN é usada para classificar quatro tipos de navios em imagens SAR de alta resolução (1,5m x 2,0m) do COSMO-SkyMed em [17]. Em [18], atingiu-se mais de 90% de acurácia na discriminação entre cinco classes de objetos metálicos no mar em imagens de alta resolução do TerraSAR-X (1,0m x 2,0m).

Em [7], foram comparadas duas CNN para extrair atributos de imagens SAR para o reconhecimento de plataformas de petróleo. Esses atributos foram submetidos a seis algoritmos de *Machine Learning* para finalizar o processo de distinção entre as plataformas de petróleo e os falsos-alarmes: kNN, Regressão Logística, SVM, *Random Forest*, Árvore de Decisão e Naïve Bayes. A melhor performance foi obtida utilizando o algoritmo de Regressão

L.Falqueto, falquetolef@fab.mil.br; R. Suterio, suterio@ita.br;
R.L.Paes, rafaelpaes@ieav.cta.br; A. Passaro, angelo@ieav.cta.br.

Logística, extraindo-se atributos por meio da VGG-16 de imagens SAR com a polarização VH, alcançando a acurácia de 86,4%, como média de 50 testes.

Não houve parametrização dos algoritmos de *Machine Learning* empregados em [7]. Experimentos adicionais podem sugerir parâmetros que permitam alcançar o desempenho obtido com imagens de alta resolução também com imagens de média resolução. Este trabalho procurou iniciar tal estudo avaliando o algoritmo de configuração mais simples: o kNN (*k-Nearest Neighbor*, em português, *k-vizinhos mais próximos*). Executou-se um experimento variando o fator k em quatro níveis ($k = [3, 7, 15 \text{ e } 31]$), utilizando a seleção do conjunto de treinamento e de teste como bloco [19]. O objetivo principal é verificar se a acurácia do classificador sofre alterações significativas ao recorrer a um ajuste de parâmetros para a tarefa proposta em [7].

O artigo apresenta na próxima seção o método empregado por [7] para o reconhecimento de plataformas marítimas e o algoritmo kNN. A Seção III apresenta a metodologia, bem como os procedimentos de avaliação do experimento, seguida dos resultados e das discussões na Seção IV.

II. REDES NEURAIS CONVOLUCIONAIS E O KNN

Em [7], duas redes neurais convolucionais, a VGG-16 e a VGG-19, foram utilizadas como extratoras de atributos de 800 amostras de imagens SAR, sendo 400 de cada polarização, 50% plataformas *offshore* e 50% falsos-almes. Esse trabalho utilizou a configuração de melhor desempenho, ou seja, a VGG-16 extraindo atributos das 400 amostras da polarização VH.

A VGG-16 é uma rede neural convolucional profunda com arquitetura ilustrada na Fig. 1 [20], [21]. Ela é composta por cinco grupos de camadas de Convolução e de *Max Pooling*, seguidas por três camadas *fully connected*. A rede usada foi aquela implementada em [22], que já é treinada no banco de dados ImageNet [23].

A última camada *fully connected* de 1000 neurônios (fc8) é substituída pelo algoritmo de classificação supervisionada

kNN, sendo esse algoritmo alimentado pelo *output* da camada anterior (fc7), isto é, por 4096 valores que compõem o vetor de atributos. Esse artifício foi utilizado, pois o conjunto de amostras é pequeno para treinar uma rede completa ou, simplesmente, a camada final de classificação.

O algoritmo kNN compara a amostra sob teste com k vizinhos mais próximos e classifica de acordo com a classe predominante, podendo ser a comparação ponderada por algum fator (peso). Para determinar os vizinhos mais próximos, a amostra é posicionada no espaço de atributos e a distância para todas as amostras de treinamento é calculada. O espaço de atributos é organizado tendo em cada dimensão (eixo) um dos atributos. Os parâmetros são o tipo de cálculo de distância, o número de vizinhos (k) e peso de cada vizinho para comparação [24].

A Fig. 2 ilustra a classificação de uma amostra por meio de kNN com o uso de distância Euclidiana, número de vizinhos igual a 3 e peso uniforme.

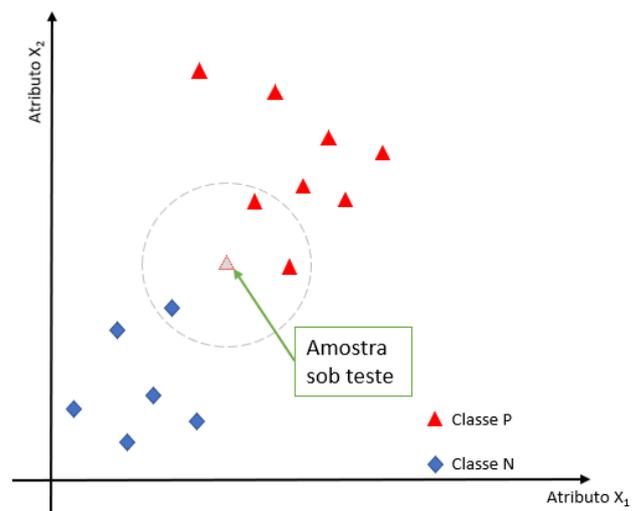


Fig. 2. Classificação utilizando o kNN, com k igual 3, distância Euclidiana e peso igual para todos vizinhos.

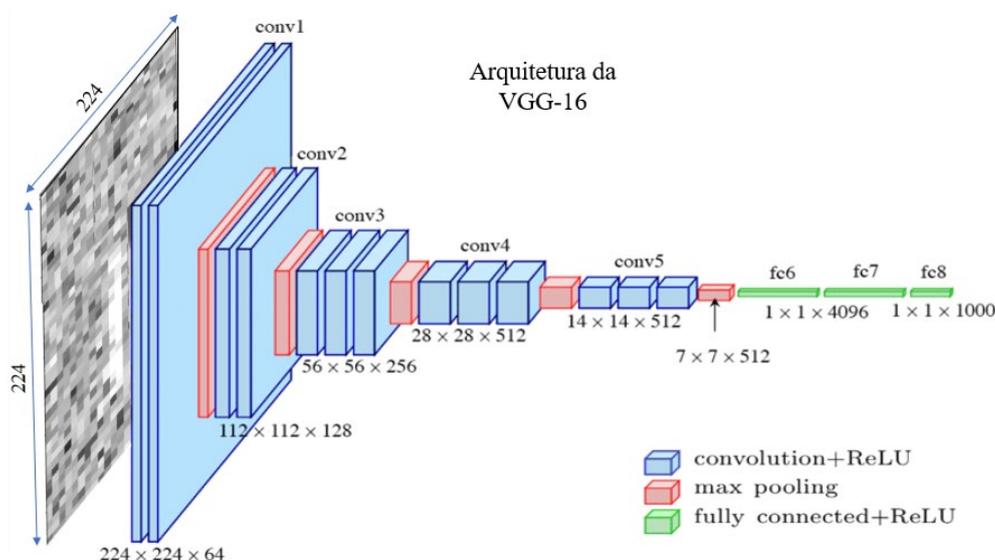


Fig. 1. Arquitetura da VGG-16. Adaptado de [26].

III. MATERIAIS E MÉTODOS

Conforme explicitado anteriormente, foram utilizadas 400 amostras na polarização VH, obtidas de imagens do satélite SAR Sentinel-1 (produto GRD), com resolução de aproximadamente 20m em *range* x 22m em azimute, *pixel spacing* de 10m x 10m, número de looks de 5 em *range* para 1 em azimute e Número Equivalente de Looks (ENL) de 4,4. Alguns exemplos de amostradas são apresentados na Fig. 3.

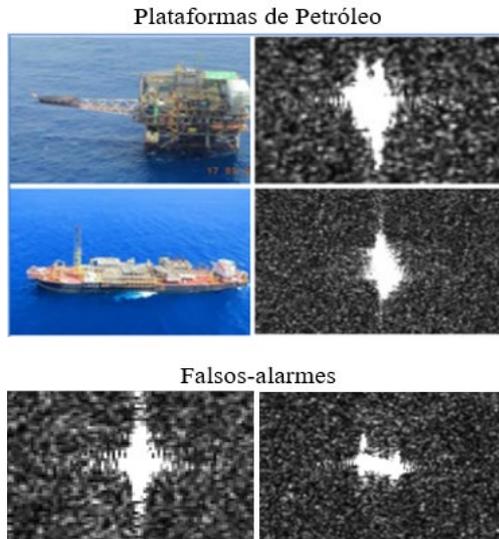


Fig. 3. Exemplo de amostras obtidas do banco de dados de [7].

Essas mesmas amostras, bem como os mesmos atributos extraídos pela VGG-16, são utilizadas para compor o conjunto de treinamento e teste para o algoritmo kNN. Note-se na Fig. 3 que as imagens SAR são muito parecidas. Isso torna a tarefa de determinar visualmente se a amostra é de uma plataforma ou não muito complexa para um especialista.

O procedimento adotado é executar 50 repetições do experimento, nas quais o conjunto de testes e o de treinamento são escolhidos a partir das 400 imagens da base de dados. Em cada repetição, 80 amostras são selecionadas aleatoriamente para compor o conjunto de teste balanceado entre plataformas e falsos-alarmes, enquanto as outras 320 compõem o conjunto de treinamento também balanceado. Por balanceado, entende-se que os conjuntos são compostos por 50% de plataformas e 50% de falsos-alarmes. Portanto, cada repetição é considerada um bloco de experimentação, de forma que a variância proveniente da seleção de amostras não afete a comparação dos tratamentos.

Cada bloco de treino e teste foi submetido ao kNN com quatro níveis para o fator número de vizinhos, ou seja, quatro tratamentos: 3 (parâmetros empregado em [7]), 7, 15 e 31. Para todos os tratamentos, foi utilizada a distância Euclidiana e o peso uniforme.

A análise foi feita com os indicadores AUC e Acurácia [25], inicialmente de forma gráfica por meio da visualização em *boxplots* da distribuição dos resultados. Posteriormente, foi feita a ANOVA, a análise de resíduos e o teste de Tukey.

Algumas informações sobre *Recall* foram extraídas para verificar se o algoritmo tende a ser conservador ou liberal, considerando as plataformas de petróleo como alvo de interesse [19].

IV. RESULTADOS E DISCUSSÃO

A Tabela I apresenta para os indicadores AUC, Acurácia e *Recall* [25] os valores de: média, mediana, variância, desvio-padrão e o *p-value* do Teste de Shapiro-Wilk [19]:

TABELA I. INFORMAÇÕES ESTATÍSTICAS PARA CADA INDICADOR

AUC				
Número de <i>k</i> vizinhos	k=3	k=7	k=15	k=31
Média	0,821	0,866	0,874	0,864
Mediana	0,824	0,862	0,870	0,868
Variância	0,002	0,001	0,002	0,002
Desvio-Padrão	0,043	0,035	0,040	0,042
<i>P-Value</i> - Teste de Shapiro-Wilk	0,888	0,725	0,726	0,890

ACURÁCIA				
Número de <i>k</i> vizinhos	k=3	k=7	k=15	k=31
Média	0,767	0,784	0,786	0,762
Mediana	0,775	0,775	0,787	0,762
Variância	0,001	0,001	0,002	0,002
Desvio-Padrão	0,038	0,038	0,042	0,048
<i>P-Value</i> - Teste de Shapiro-Wilk	0,361	0,374	0,623	0,380

RECALL				
Número de <i>k</i> vizinhos	k=3	k=7	k=15	k=31
Média	0,800	0,831	0,840	0,827
Mediana	0,800	0,825	0,850	0,825
Variância	0,003	0,003	0,004	0,003
Desvio-Padrão	0,054	0,059	0,064	0,054
<i>P-Value</i> - Teste de Shapiro-Wilk	0,059	0,179	0,244	0,150

A Fig. 4 e a Fig. 5 apresentam graficamente as distribuições dos resultados para os indicadores AUC e Acurácia para cada um dos tratamentos:

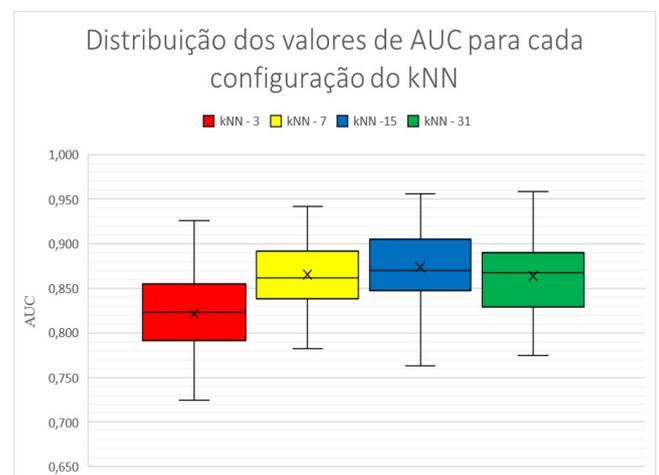


Fig. 4. Resultados do indicador AUC por número de vizinhos.

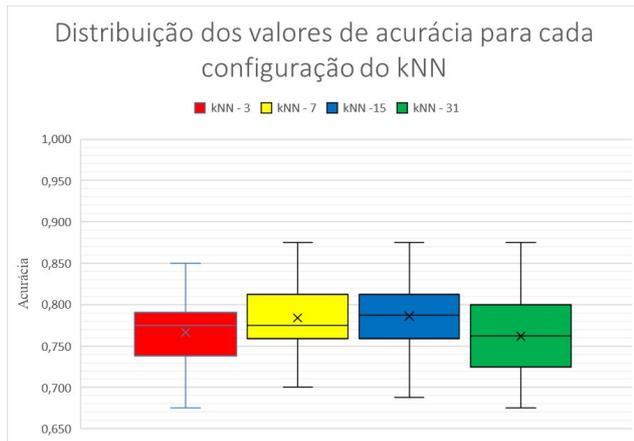


Fig. 5. Resultados do indicador Acurácia por número de vizinhos.

A Tabela II apresenta os resultados da ANOVA tanto para o indicador AUC, quanto para o indicador Acurácia, mostrando que há diferença estatística (significância de 5%) para as médias das distribuições das Fig. 4 e Fig. 5.

TABELA II. ANOVA PARA AUC E PARA ACURÁCIA

ANOVA (AUC)					
Fonte da variação	SQ	gl	MQ	F	valor-P
Tratamentos	0,083	3	0,0278	68,34	2,00E-16
Blocos	0,258	49	0,0053	-	-
Resíduos	0,06	147	0,0004	-	-
Total	0,401	199	-	-	-

ANOVA (Acurácia)					
Fonte da variação	SQ	gl	MQ	F	valor-P
Tratamentos	0,022	3	0,0073	10,07	4,47E-06
Blocos	0,234	49	0,0048	-	-
Resíduos	0,107	147	0,0007	-	-
Total	0,363	199	-	-	-

A análise dos resíduos da ANOVA para o indicador AUC apresenta o valor-p para o teste de normalidade de 0,173 (Teste de Shapiro-Wilk - $W = 0,9899$), e para o teste de homogeneidade das variâncias de $4,8E-05$ (Teste de Bartlett).

A análise dos resíduos da ANOVA para o indicador Acurácia apresenta o valor-p para o teste de normalidade de 0,9503 (Teste de Shapiro-Wilk - $W = 0,99672$), e para o teste de homogeneidade das variâncias de 0,0153 (Teste de Bartlett).

O Teste de Tukey (significância de 5%) de ambos os indicadores é apresentado na Tabela III.

TABELA III. TESTE DE TUKEY PARA AUC E ACURÁCIA

Tratamento	IC-95% AUC	Grupos AUC	IC-95% Acurácia	Grupos Acurácia
kNN - 15	[0,867 - 0,881]	a	[0,776 - 0,796]	a
kNN - 7	[0,858 - 0,873]	a	[0,774 - 0,794]	a
kNN - 31	[0,857 - 0,871]	a	[0,752 - 0,772]	b
kNN - 3	[0,814 - 0,829]	b	[0,757 - 0,776]	b

Conforme esperado, os classificadores necessitam de uma parametrização adequada para alcançar o melhor desempenho, pois a ANOVA tanto para Acurácia, quanto para AUC são significativas, demonstrando que há diferença na média dos tratamentos. Houve melhora de 6,46% na AUC, 5% no *Recall* e 3,14% na Acurácia, considerando o tratamento com pior e com o melhor desempenho.

O fato de o *Recall* apresentar uma melhora percentual de praticamente o dobro da Acurácia representa que a parametrização impactou mais o reconhecimento das plataformas de petróleo do que o dos falsos-alarmes. O *Recall* é a proporção de plataformas corretamente previstas com o total dessa classe existente no teste. A Acurácia considera os acertos de ambas as classes em seus cálculos.

Ressalta-se que o classificador tem um comportamento liberal, ou seja, acerta bastante a classe positiva (plataformas de petróleo), mas também tende a errar mais a classe negativa (falsos-alarmes). Ao comparar a tabela de *Recall* com a Acurácia, percebe-se que primeiro indicador é maior que o segundo em todos os tratamentos, uma característica para um classificador liberal, quando atuando em classificação binária balanceada.

Foram testadas as quantidades de vizinhos que variam de 0,93% da massa de treinamento ($k=3$) a 9,69% ($k=31$). A quantidade de vizinhos influencia como o classificador tende a perceber a topologia do espaço de atributos. Quanto maior, mais tende-se a classificar de acordo com um comportamento regional dentro do espaço de atributos, pesando menos os detalhes locais. Assim, quanto maior k , supõe-se que os ruídos afetem menos a classificação, porém tende-se a suavizar as bordas dos limites entre as classes. Com isso, classes não-linearmente separáveis podem ser de difícil distinção ao utilizar um k muito grande em termos proporcionais ao conjunto de treinamento.

Para os resultados do experimento, percebe-se que $k=3$ apresenta o pior resultado, com média igual 0,0767. Portanto, o número muito pequeno de vizinhos provavelmente sofreu influência dos ruídos locais.

Ao utilizar o $k=31$, não se percebe melhora significativa. Na verdade, a média de todos indicadores começa a cair. Pode-se inferir que as classes possuem limites complexos. Para um número de vizinhos muito grande, o classificador deixa de ser sensível aos detalhes das fronteiras entre as classes. Além disso, um número maior de vizinhos exige um poder computacional maior, devido a maior quantidade de comparações necessárias.

Para essa base de dados, provavelmente o número de vizinhos ideal estaria próximo a 15, ou seja, em torno de 5% do conjunto de treinamento. Quanto aos resultados da referência [7], notou-se uma melhoria de 5,9% na AUC, passando de 0,825 para 0,874, confirmando que a parametrização do algoritmo oferece mudanças significativas em termos operacionais e estatísticos.

V. CONCLUSÃO

Nesse trabalho, continuou-se uma pesquisa que utilizou Redes Neurais Convolucionais para extrair os atributos de

imagens SAR de média resolução de plataformas de petróleo (alvos de interesse) e falsos-alarmes. O objetivo era verificar se a parametrização do classificador que processava tais atributos tinha influência significativa no desempenho do reconhecimento automático desses alvos artificiais.

O classificador empregado foi o kNN e testou-se o parâmetro número de vizinhos em quatro níveis ($k = [3, 7, 15$ e $31]$). Chegou-se à conclusão de que há diferença na performance, sendo que os tratamentos com 7 e 15 vizinhos alcançaram as melhores médias para os três indicadores utilizados. Percebeu-se que o kNN tem um comportamento liberal para o tipo de alvo classificado.

Como trabalhos futuros, sugere-se um estudo mais detalhado da parametrização do kNN, bem como dos demais algoritmos empregados na pesquisa de base desse trabalho, para que se possa atingir o estado-da-arte em algoritmos ATR usando imagens de média resolução. A ampliação do banco de amostras também pode contribuir para resultados melhores. Além disso, seria interessante testar o kNN associado à VGG-16 em outras bases de dados de imagens SAR com mais classes para verificar se o comportamento do algoritmo é semelhante.

Contribuiu-se para a melhoria de sistemas de vigilância de grandes áreas, de forma que o controle da Amazônia Azul, por exemplo, seja beneficiado pelo emprego de técnicas ATR que usam a abundância de dados gerada pelos sensores espaciais.

REFERÊNCIAS

- [1] Comando da Aeronáutica, Ministério da Defesa, and Brasil, "Dimensão 22," 2018. [Online]. Available: <http://www.fab.mil.br/dimensao22>. [Accessed: 02-Apr-2018].
- [2] IEEE GRSS Beijing Chapter and RADL, "Proceedings of 2017 SAR in Big Data Era: Models, Methods and Applications, BIGSAR DATA 2017," *Proc. 2017 SAR Big Data Era Model. Methods Appl. BIGSAR DATA 2017*, vol. 2017-Janua, p. 2017, 2017.
- [3] F. Palazzo *et al.*, "RUS: A New Expert Service for Sentinel Users," *Proceedings*, vol. 2, no. 7, p. 369, 2018.
- [4] A. G. Castriotta and R. Knowelden, "COPE-SERCO-RP-17-0186: Sentinel Data Access 2017 Annual Report," Frascati, 2018.
- [5] J. Blumenfeld, "Getting Ready for NISAR — and for Managing Big Data using the Commercial Cloud," *ASF News*, 2018. [Online]. Available: <https://www.asf.alaska.edu/news-notes/winter-2017-1/getting-ready-for-nisar/>.
- [6] A. Marino, D. Velotto, and F. Nunziata, "Offshore Metallic Platforms Observation Using Dual-Polarimetric TS-X/TD-X Satellite Imagery: A Case Study in the Gulf of Mexico," *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 10, no. 10, pp. 4376–4386, Oct. 2017.
- [7] L. E. Falqueto, J. A. S. Sa, R. L. Paes, and A. Passaro, "Oil Rig Recognition Using Convolutional Neural Network on Sentinel-1 SAR Images," *IEEE Geosci. Remote Sens. Lett.*, pp. 1–5, 2019.
- [8] PETROBRAS, "Tipos de plataformas," 2018. [Online]. Available: <http://www.petrobras.com.br/infograficos/tipos-de-plataformas/desktop/index.html>. [Accessed: 15-Jun-2018].
- [9] D. Zhang, J. Liu, W. Heng, K. Ren, and J. Song, "Transfer Learning with Convolutional Neural Networks for SAR Ship Recognition," *IOP Conf. Ser. Mater. Sci. Eng.*, vol. 322, no. 7, p. 072001, Mar. 2018.
- [10] S. Chen, H. Wang, F. Xu, and Y. Q. Jin, "Target Classification Using the Deep Convolutional Networks for SAR Images," *IEEE Trans. Geosci. Remote Sens.*, vol. 54, no. 8, pp. 4806–4817, 2016.
- [11] M. Wilmanski, C. Kreucher, and J. Lauer, "Modern approaches in deep learning for SAR ATR," in *Modern approaches in deep learning for SAR ATR, Proc. SPIE 9843*, 2016, no. 98430N, p. 10.
- [12] J. Pei, Y. Huang, W. Huo, Y. Zhang, J. Yang, and T.-S. Yeo, "SAR Automatic Target Recognition Based on Multiview Deep Learning Framework," *IEEE Trans. Geosci. Remote Sens.*, vol. 56, no. 4, pp. 1–15, 2017.
- [13] H. Furukawa, "SAVERS: SAR ATR with Verification Support Based on Convolutional Neural Network," pp. 23–28, 2018.
- [14] F. Gao, T. Huang, J. Sun, J. Wang, A. Hussain, and E. Yang, "A New Algorithm of SAR Image Target Recognition Based on Improved Deep Convolutional Neural Network," *Cognit. Comput.*, vol. 18, no. 1, pp. 25–30, Jun. 2018.
- [15] F. Gao, Y. Yang, J. Wang, J. Sun, E. Yang, and H. Zhou, "A Deep Convolutional Generative Adversarial Networks (DCGANs)-Based Semi-Supervised Method for Object Recognition in Synthetic Aperture Radar (SAR) Images," *Remote Sens.*, vol. 10, no. 6, p. 846, May 2018.
- [16] E. G. Zelnio, M. Levy, R. D. Friedlander, and E. Sudkamp, "Deep learning model-based algorithm for SAR ATR," *Algorithms Synth. Aperture Radar Imag. XXV*, no. May, p. 10, 2018.
- [17] C. Wang, H. Zhang, F. Wu, B. Zhang, and S. Tian, "Ship classification with deep learning using COSMO-SkyMed SAR data," in *2017 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, 2017, pp. 558–561.
- [18] C. Bentes, D. Velotto, and B. Tings, "Ship Classification in TerraSAR-X Images With Convolutional Neural Networks," *IEEE J. Ocean. Eng.*, vol. 43, pp. 258–266, Jan. 2017.
- [19] D. C. Montgomery, *Design and Analysis of Experiments*, Eighth. Arizona: John Wiley & Sons, Inc., 2013.
- [20] K. Simonyan and A. Zisserman, "Very Deep Convolutional Networks for Large-Scale Image Recognition," *Inf. Softw. Technol.*, vol. 51, no. 4, pp. 769–784, Sep. 2014.
- [21] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. MIT Press, 2016.
- [22] J. Demšar *et al.*, "Orange: Data Mining Toolbox in Python," *J. Mach. Learn. Res.*, vol. 14, pp. 2349–2353, 2013.
- [23] O. Russakovsky *et al.*, "ImageNet Large Scale Visual Recognition Challenge," *Int. J. Comput. Vis.*, vol. 115, no. 3, pp. 211–252, Dec. 2015.
- [24] S. B. Kotsiantis, I. D. Zaharakis, and P. E. Pintelas, "Machine learning: a review of classification and combining techniques," *Artif. Intell. Rev.*, vol. 26, no. 3, pp. 159–190, Nov. 2006.
- [25] T. Fawcett, "An introduction to ROC analysis," *Pattern Recognit. Lett.*, vol. 27, no. 8, pp. 861–874, 2006.
- [26] M. Ferguson, R. Ak, Y.-T. T. Lee, and K. H. Law, "Automatic localization of casting defects with convolutional neural networks," no. December, pp. 1726–1735, 2018.