MULTICLASIFICAÇÃO DE LOOK-ALIKES EM IMAGENS DE SENSORIAMENTO REMOTO UTILIZANDO REDES NEURAIS CONVOLUCIONAIS

Caique Emanuel da Silva Nunes[a,b]
caique.nunes@ufpe.br

Isis Didier Lins[a,b]
isis.lins@ufpe.br

Márcio José das Chagas Moura[a,b]
marcio.cmoura@ufpe.br

Luis Felipe Ferreira de Mendonça[c]
luis.mendoca@ufba.br

Carlos Alessandre Domingos Lentini[c]
clentini@ufba.br

André Telles da Cunha Lima[c]
at.cunhalima@ufba.br

[a]Centro de Estudos e Ensaios em Risco e Modelagem Ambiental (CEERMA)
[b]Universidade Federal de Pernambuco (UFPE)
Av. da Arquitetura, s/n – Cidade Universitária, Recife – PE, 50740-550
[c]Universidade Federal da Bahia (UFBA)
Av. Adhemar de Barros, s/n – Ondina, Salvador – BA

RESUMO

A indústria de óleo e gás tem investido em tecnologias de inteligência artificial que sejam capazes de detectar automaticamente vazamentos de óleo no mar. No entanto, a identificação desses vazamentos é dificultada por outros fenômenos oceanográficos, conhecidos como look-alikes. Para contornar este problema, propomos um modelo de multiclassificação desenvolvido com base em uma rede neural convolucional para classificar alguns look-alikes e aumentar a precisão na detecção de óleo. O modelo foi treinado com o banco de dados TenGeoP – SARwv, composto por imagens do satélite Sentinel-1, com dez classes distintas de falsos positivos. O modelo apresentou uma acurácia de cerca de 70% numa arquitetura que considera 10 classes distintas de falsos positivos e de quase 80% quando foram usadas apenas sete destas classes. Ainda há oportunidades de ajuste para aumentar a precisão do modelo, de acordo com os valores da função perda.

PALAVRAS CHAVE. Multiclassificação, Look-alikes, Redes Neurais Convolucionais, Sensoriamento remoto, Indústria de Óleo e Gás.

Tópicos (IC - Inteligência Computacional, EN&PG – PO na Área de Energia, Petróleo e Gás)

ABSTRACT

DOI: 10.59254/sbpo-2023-174938
http://live-proceedings.pantheonsite.io/p/174938

The oil and gas industry has invested in artificial intelligence technologies that are capable of automatically detecting oil spills at sea. However, identifying these spills is hampered by other oceanographic phenomena, known as look-alikes. To overcome this problem, we propose a multiclassification model developed based on a convolutional neural network to classify some look-alikes and increase accuracy in oil. The model was trained with the TenGeoP – SARwv database, composed of Sentinel-1 satellite images with ten different look-alike classes. The model presented an accuracy of around 70% in an architecture that considers ten distinct classes of look-alikes and almost 80% when only seven classes were used. There are still opportunities for adjustments to increase the accuracy of the model, according to the values of the loss function.

KEYWORDS. Multiclassification. Look-alike. Convolutional Neural Networks. Remote sensing. Oil & Gas.

Paper topics (IC - Computational Intelligence, EN&PG – OR in the Area of Energy, Oil and Gas)

DOI: 10.59254/sbpo-2023-174938
http://live-proceedings.pantheonsite.io/p/174938

1. Introdução

O mundo vivencia a evolução da digitalização de coisas e processos. A motivação para isso está na vasta possibilidade de aplicações e na busca pela otimização de resultados. Na indústria de óleo e gás, por exemplo, o monitoramento extensivo de mares e oceanos com o intuito de identificar e controlar vazamentos de óleo é uma atividade que tem sido aprimorada com o aporte computacional.

Embora os grandes acidentes derramem óleo no mar numa escala muito maior, a poluição do ambiente marinho devido a atividades rotineiras de navios tanques e cargueiros, de plataformas offshore e de perfuração de poços é mais recorrente [de la Huz et al., 2019; B. Zhang et al., 2019]. De uma forma geral, estes eventos não são planejados e quando acontecem provocam um desequilíbrio em todo o ecossistema envolvido, impactos sociais e perdas financeiras. Isso explica a necessidade de monitoramento constante de áreas oceânicas [Negreiros et al., 2022].

Os ambientes marinhos são muito dinâmicos e a ocorrência de desastres com óleo podem ser praticamente incontroláveis, atingindo dimensões de centenas de quilômetros. À medida que o desastre se espalha, mais complicada e, consequentemente, mais cara é a sua contingência. Tendo como exemplo, o custo com a limpeza das praias foi estimado em cerca de 188 milhões de reais [Platonow, 2021] devido ao acidente ocorrido em 2019 que afetou o litoral brasileiro [Soares e Rabelo, 2023].

E a tendência é de que o vazamento de óleo no mar fique cada vez mais caro pois a cultura e consciência sustentável de environmental, social, governance (ESG) está num patamar mais alto no ranking de investidores e governos. E já se pode dizer que empresas que negligenciam os fatores social e de meio ambiente, ou seja que apresentam baixa pontuação ESG, estão sendo penalizadas financeiramente [Litvinenko et al., 2022; Shakil, 2021]. Dessa forma, fica claro como a rápida identificação e contenção do vazamento é extremamente importante [Brekke e Solberg, 2005].

Como o óleo mineral tem constituintes hidrofóbicos, ele pode persistir na superfície do oceano na forma de várias camadas [Alpers et al., 2017]. Quando derramado no mar, o óleo mineral recebe os processos de intemperismo, como: evaporação, emulsificação, biodegradação, dispersão, dissolução e oxidação [Chaturvedi et al., 2020]. A presença de fluidos de alta viscosidade na água do mar altera a tensão da superfície do oceano e induz a atenuação das ondas capilares e gravitacionais. [Alpers & Hühnerfuss, 1989]. Portanto, os derramamentos de óleo no mar aumentam a tensão da superfície da água e reduz a rugosidade da superfície do mar. A supressão do espalhamento de Bragg permite reconhecer os derramamentos de óleo como regiões de baixa retroespalhamento pelos sensores de radar [Benelli & Garzelli,1999].

Porém, não são apenas os óleos minerais que apresentam este comportamento, outras emulsões também, são capazes de suprimir as ondas capilares oceânicas e reduzir o espalhamento de Bragg. Estes alvos são conhecidos como look-alikes ou falsos positivos, que segundo [Topouzelis et al. 2007], são regiões da imagem que têm estruturas de formações escuras com padrões parecidos com de vazamento de óleo. Entretanto, as razões para as formações escuras são naturais, como nuvens, biofilme, áreas de frente de vento, e não ações humanas. [Liu et al., 2023] reforçam ainda que falsos positivos são um obstáculo considerável no discernimento de vazamentos de óleo em imagens.

Dada a importância de detectarmos de fora rápida e objetiva alvos de óleo, propomos aqui, aprimorar a detecção automática de vazamento de óleo, criando uma forma de diferenciar os falsos positivos dos reais vazamentos de óleo. Após revisão de literatura, este se mostrou ser um problema reincidente ainda pouco tratado, caracterizando uma oportunidade de pesquisa.

A solução proposta neste estudo é treinar a máquina para reconhecer padrões de diferentes tipos de look-alikes. Para isso foi utilizado um modelo de multiclassificação para interpretar padrões complexos dos look-alikes e classificá-los dentre mais de uma classe. A arquitetura do modelo de aprendizagem de máquina desenvolvido para este estudo envolve redes neurais convolucionais (CNN). Em poucas palavras, as CNNs aplicam operações de convolução para extrair características relevantes de imagens e, na camada de saída, tem-se efetivamente a classificação da imagem em uma das categorias consideradas.

DOI: 10.59254/sbpo-2023-174938
http://live-proceedings.pantheonsite.io/p/174938

Ao aprender a distinguir entre os diferentes tipos de fenômenos oceanográficos que podem ser capturados por imagens de satélite de maneira similar a vazamentos de óleo, o modelo de inteligência artificial terá uma maior capacidade de discernimento entre um vazamento real e um falso-positivo. Quando agregado a um sistema que analise imagens mais gerais do oceano, o aprendizado do modelo proposto neste artigo será de grande valia pois permitirá identificar com mais precisão os fenômenos e contribuirá para que os esforços sejam voltados apenas para vazamentos reais. Sendo assim, o gerenciamento de riscos será mais eficaz e se espera uma redução das consequências.

2. Revisão da Literatura

2.1 Look-alike

É comum utilizar imagens de satélite para monitorar áreas oceânicas, sendo a técnica Synthetic Aperture Radar (SAR) a mais empregada na maioria dos casos. Essa técnica de sensoriamento remoto usa sensores ópticos e de micro-ondas para gerar imagens independentemente das condições climáticas, de iluminação e do tempo [Raeisi et al., 2018; Yekeen & Balogun, 2020].

As micro-ondas de energia emitidas pelos satélites são sensíveis e refletem a rugosidade do mar. Nas imagens geradas pelo satélite, as áreas que apresentam derramamento de óleo se destacam como pontos escuros, já que reduzem a energia que retorna ao satélite [Amri et al., 2022; Yekeen e Balogun, 2020].

No entanto, vazamento de óleo não é a única razão para a presença de manchas escuras nas imagens. Outros fenômenos oceanográficos, conhecidos como "look-alike"(como ventos baixos, manchas biológicas, gelo marinho, células de nuvens, entre outros), podem ser responsáveis pelas áreas mais escuras nas imagens [Schistad Solberg et al., 1999]. Inclusive, a maioria das imagens coletadas com a finalidade de monitorar os oceanos irá conter esses tipos de fenômenos.

Assim, torna-se ainda mais importante discriminar com precisão as áreas escuras como sendo resultado de vazamento de óleo ou de look-alikes [Dhavalikar e Choudhari, 2021]. Cientificamente, vazamentos de óleo e fenômenos semelhantes apresentam propriedades físicas diferentes e, portanto, reagem de maneiras distintas sob determinadas condições [Guo & Zhang, 2014].

[Bhangale et al., 2017; Raeisi et al., 2018; Yekeen e Balogun, 2020] destacam a forma geométrica da área escura na imagem SAR como um importante atributo para extração de características. Isso se deve à facilidade de extrair características, mesmo em imagens de baixa qualidade, se comparado a outros atributos, e à eficiência computacional em processá-las.

Atributos como valores médios, desvio padrão, valores na escala de cinza, complexidade, solidez e orientação são exemplos de características que podem ser extraídas da forma geométrica dos pontos escuros presentes nas imagens SAR. Esses atributos permitem uma melhor observação e definição do fenômeno em questão.

2.2 Redes neurais convolucionais (CNN)

As primeiras arquiteturas de treinamento de modelos de aprendizagem de máquina foram construídas pretendendo reproduzir o funcionamento do cérebro humano. O cérebro é composto por células interconectadas chamadas neurônios. Similarmente, em um modelo de aprendizagem de máquina os perceptrons são organizados conectados uns aos outros e transferem informações usando uma função de ativação.

Assim como as redes neurais mais simples, as CNNs (do inglês Convolutional Neural Networks) tem a finalidade de simular a forma como o cérebro humano reconhece imagens. Embora os dados de entrada sejam geralmente imagens, as redes CNN também podem ser usadas para trabalhar com vetores de características, texto e sons. Isso se deve ao fato de elas fazerem parte da área de aprendizagem de máquina que são especializadas em reconhecimento de padrões.

A CNN funciona, resumidamente, com a definição de um filtro (kernel) que tem a missão de buscar por um padrão entre os dados de input do modelo. Matematicamente, teremos uma convolução gerada toda vez que o filtro passa por uma pequena quantidade de pixels e é dessa

DOI: 10.59254/sbpo-2023-174938
http://live-proceedings.pantheonsite.io/p/174938

forma que um padrão desejado é identificado. Uma convolução é uma operação matemática em que dois objetos produzem um output que mostra como a forma de um é modificado pelo outro [Goodfellow et al., 2016].

Além da camada de convolução, as CNNs são, geralmente, compostas por outras três camadas de diferentes funcionalidades: pooling, dense e flatten. A camada de pooling é responsável por reduzir o tamanho da representação da imagem, reduzindo os ruídos e mantendo as principais características. Já a camada dense é usada para fazer a classificação final das características extraídas, combinando as informações anteriores. A camada intermediária, que permite a conexão entre as camadas de convolução e pooling e as camadas dense achatando as informações num vetor unidimensional, é a flatten [Atila & Şengür, 2021].

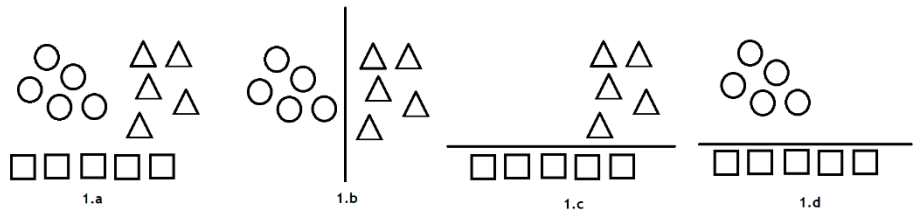
2.3 Multiclassificação

Fazer uma predição a partir de um treinamento com dados disponíveis é uma das tarefas mais comum no âmbito da inteligência computacional. Este tipo de demanda também é habitualmente referido como problemas de classificação. Problemas de classificação são tipicamente binários, envolvendo apenas duas classes. A classificação é feita por meio de técnicas de probabilidade e estatística e, em geral, a regra básica é simples: o objeto em análise é atribuído à classe que apresentar a maior probabilidade associada [Grandini et al., 2020].

Entretanto, num contexto mais abrangente, pode ser que se faça necessário categorizar um objeto em uma de K classes. Nesses casos envolvendo pelo menos três classes diferentes, a tarefa é denominada como problema de multiclassficação ou de classificação multiclasse. Algoritmicamente, problemas de multiclassificação se resolvem de forma muito similar aos de classificação binária [Yang et al., 2014].

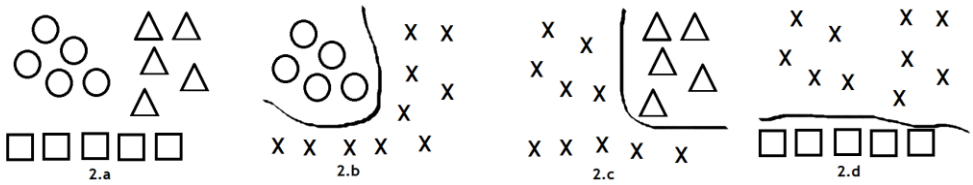
Há dois procedimentos frequentemente empregados para a resolução de um problema de multiclassificação: um contra um e um contra o resto (one-vs-one e one-vs-rest, em inglês, respectivamente). As Figuras 1 e 2 sumarizam os procedimentos e ajudam o entendimento do funcionamento deles.

Figura 1 – Procedimento um contra um



Fonte: os autores (2023), adaptado de [Z. Zhang et al., 2016]

Figura 2 – Procedimento um contra o resto



Fonte: os autores (2023), adaptado de [Yang et al., 2014]

A figura 1 mostra como é operado o procedimento um contra um: a Figura 1.a representa as imagens de treinamento no sistema, e as Figuras 1.b, 1.c e 1.d apresentam as repetidas etapas de classificação binária são realizadas classe a classe. No final, o processo deverá ser repetido $(k(k-1))/2$ vezes e um método de votação é utilizado para estabelecer a qual classe a imagem pertence [Ma et al., 2020].

DOI: 10.59254/sbpo-2023-174938
http://live-proceedings.pantheonsite.io/p/174938

Já a execução do procedimento um contra o resto é apresentada na Figura 2. Novamente, as imagens de treinamento no sistema estão representadas na Figura 2.a. Contudo, agora as etapas são repetidas apenas k vezes e a classificação binária é realizada entre uma classe e todas as outras e não mais entre cada duas classes, como mostram as Figuras 2.b, 2.c e 2.d [Yang et al., 2014; M. Zhang et al., 2022].

Modelos de aprendizagem de máquina que abrangem problemas de multiclassificação tem uma aplicabilidade que vai desde o processamento de linguagem natural [Y.-C. Wu et al., 2008] até o auxílio no diagnóstico de doenças, classificando os pacientes de acordo com suas condições de saúde [Jabbar et al., 2023; Maior et al., 2021; Mohammed et al., 2022; J. Wu et al., 2023; Yuan et al., 2022]. Neste trabalho adotamos os conceitos de multiclassificação para lidar com classes diferentes de look-alike e desta forma aprimorar a detecção automática de vazamento de óleo em oceanos.

3. Dataset

O banco de dados utilizado nesta pesquisa é o TenGeoP – SARwv [Wang et al., 2019]. Esse banco de dados é formado por imagens selecionadas das que são disponibilizadas pela Agência Espacial Europeia (ESA – European Space Agency) através do programa Copernicus. As imagens foram coletadas pela polarização VV (polarização vertical transmitida – polarização vertical recebida) geradas por dois satélites Sentinel-1 (A e B) através do sistema Wave Mode. A polarização VV é utilizada pois apresenta a melhor a melhor relação sinal-ruído sobre a superfície do mar.

O TenGeoP – SARwv foca em dez condições atmosféricas e oceânicas comumente observadas que geram manchas escuras nas imagens de radar coletadas dos satélites, ou seja, look-alikes. Somente a condição predominante é selecionada como etiqueta da imagem. Logo, cada imagem do banco de dados pode ser classificada apenas como um dos dez fenômenos geofísicos apresentados na Tabela 1. Cada um dos satélites é capaz de gerar 60 mil imagens em um mês. Todavia, o TenGeoP – SARwv é formado por 37.553 imagens. Cerca de 400 imagens de cada classe foram selecionadas para cada um dos 12 meses do ano. Isso só não foi possível para a classes de frente oceânica (não se conseguiu chegar a esse número) e de iceberg (devido à sazonalidade). Na Tabela 1 também são expostas as quantidades e as porcentagens de cada classe no banco de dados.

Tabela 1 – Dez classes de look-alike

#	Tipo de look-alike	Descrição	# Imagens (%)
1	Ondas oceânicas puras	Prevalente na maioria das imagens	4900 (13%)
2	Ondas de vento	Rugosidade formada pela força do vento	4797 (13%)
3	Células microconectivas	Estruturas de correntes	4598 (12%)
4	Células de chuva	Formas de chuva	4740 (13%)
5	Manchas biológicas	Manchas formadas por seres aquáticos	4709 (13%)
6	Gelo marinho	Água salgada congelada	4370 (12%)
7	Iceberg	Água doce congelada	1980 (5%)
8	Área de vento baixo	Mar quase estacionário	2160 (6%)
9	Frente atmosférica	Duas frentes de ar/vento distintas	4100 (11%)
10	Frente oceânica	Encontro de águas de massas distintas	1199 (3%)
		Total	37553 (100%)

Fonte: os autores (2023), adaptado de [Wang et al., 2019]

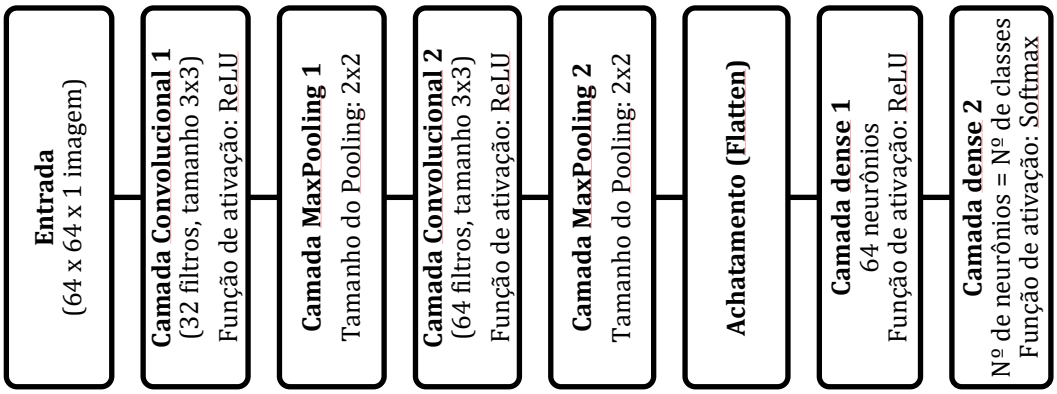
4. Modelo

DOI: 10.59254/sbpo-2023-174938
http://live-proceedings.pantheonsite.io/p/174938

Para esta pesquisa foi desenvolvido um modelo baseado em arquiteturas comuns de visão computacional [Sharma et al., 2018] que tem como objetivo ser capaz de fazer a multiclassificação de imagens de fenômenos oceanográficos coletadas por radar de satélites. O intuito é treinar para que o modelo seja capaz de identificar falsos positivos e ter uma informação adicional, de forma a evitar falsos positivos e detectar reais vazamentos de óleo no mar.

A linguagem de programação escolhida para construção do modelo foi Python por ser uma linguagem prestigiada por cientistas de dados e engenheiros. E a base do código foi elaborada com Keras [Gulli & Pal, 2017], que é uma biblioteca propícia para a construção de redes neurais artificiais. A Figura 3 mostra de uma maneira concisa, a rede neural convolucional que foi desenvolvida para classificar look-alikes nas múltiplas classes.

Figura 3 – Arquitetura do modelo



Fonte: os autores (2023)

Primeiramente o modelo carrega, redimensiona para um tamanho definido e converte para a escala de cinza as imagens do banco de dados TenGeoP – SARwv. O modelo também carrega os rótulos das imagens e os codifica como números inteiros correspondentes às dez classes de imagens.

O modelo converte as imagens e os rótulos em matrizes numéricas com o intuito de garantir um processamento mais eficiente, em termos de memória e desempenho. E depois disso o modelo divide tanto os dados das imagens quanto dos rótulos em conjuntos de treinamento e de teste. A função ‘split’ que é usada para esta divisão tem dois argumentos principais: a proporção de dados de imagens que são alocados para teste, 20% neste modelo, e um valor para assegurar que a divisão será sempre a mesma.

Além disso, o modelo normaliza as matrizes com os dados das imagens para garantir que todas as features (pixels) tenham a mesma escala, o que ajuda o modelo a convergir mais rapidamente e a evitar que algumas features dominem outras[Singh & Singh, 2020]. E os dados dos rótulos são codificados como ‘one-hot vectors’, que são vetores binários com comprimento k (número de classes), onde o índice correspondente à classe é marcado como 1 e todos os outros índices são marcados como 0. Dessa forma, o modelo trata cada classe como uma categoria independente, sem atribuir uma ordem implícita.

Em seguida, o modelo é programado para processar os dados pela CNN de arquitetura composta por camadas convolucionais, de pooling, flatten e dense. Fica definida no compilador a configuração do processo de treinamento do modelo. O otimizador escolhido foi o ‘adam’, que é um algoritmo de otimização estocástica que atualiza os pesos da rede neural durante o treinamento. A função de perda do modelo é a ‘categorical_crossentropy’, que assim como o otimizador é frequentemente usada em problemas de multiclassificação.

A função de perda ‘categorical_crossentropy’ calcula a diferença entre o valor real e a probabilidade prevista da classe. E a função ‘softmax’ transforma as saídas numéricas de um conjunto de neurônios em valores de probabilidade que somam 1, ou seja, a saída da rede é uma probabilidade para cada classe possível.

DOI: 10.59254/sbpo-2023-174938
http://live-proceedings.pantheonsite.io/p/174938

O treinamento do modelo é feito pelo método ‘fit’. Os dois principais parâmetros do método de treinamento do modelo são: o tamanho do lote (batch_size) que indica o número de amostras que serão usadas em cada iteração de treinamento; e o número de épocas (epochs) que especifica o número de vezes que o modelo irá iterar sobre o conjunto de treinamento completo. Este método retorna um objeto que contém informações sobre as métricas de treinamento e validação em cada época.

O desempenho do modelo com o conjunto de dados de testes é avaliado pelo método ‘evaluate’. O método retorna um vetor de métricas que, no modelo em estudo, inclui a perda e a acurácia. Segundo [Grandini et al., 2020] uma das métricas mais utilizadas na multiclassificação é a acurácia. A acurácia mede a proporção de previsões corretas que o modelo fez em relação ao número total de previsões realizadas.

Por último, o modelo faz previsões com novas imagens. O método ‘predict’ aceita uma imagem de look-alike como entrada, usa o modelo treinado para obter o índice da classe com maior probabilidade, e retorna o nome da classe prevista para a imagem de entrada. As probabilidades previstas das dez classes de look-alike para a imagem de entrada são plotadas em um gráfico de barras para comparação.

5. Testes e Resultados

Para os testes e análises, a arquitetura do modelo desenvolvido foi parametrizada com as imagens sendo dimensionadas para o tamanho 64x64 (altura x largura) pixels; 80% do banco de dados separado para treinamento e 20% para testes do modelo; e o treinamento foi repetido por 10 épocas, sendo 32 o tamanho dos lotes para treinamento.

O primeiro teste para classificação multiclasse de look-alikes foi realizado com o modelo conforme descrito, com os parâmetros relatados acima, usando as 10 classes apresentadas no banco de dados TenGeoP – SARwv (Tabela 1). Como output, observou-se que a acurácia do modelo aumentou gradualmente em cada época tanto no conjunto de treino quanto no conjunto de validação. Porém, a partir da quinta época, a acurácia do conjunto de validação começou a estabilizar e até mesmo diminuir em algumas épocas.

Com relação aos resultados dos dados de teste, o modelo obteve uma perda de 1,2827 e uma acurácia de 0,6642. A perda é uma métrica que indica o quão bem o modelo se ajustou aos dados de treinamento, sendo que valores menores indicam um melhor ajuste. Por outro lado, a acurácia mede a proporção de classificações corretas em relação ao total de classificações feitas pelo modelo.

Esses resultados chamaram atenção por estarem abaixo do esperado e, portanto, foram investigados. Ao fazer uma média de previsões com imagens de cada classe separadamente, foi observado que os menores valores estavam relacionados às classes de gelo marinho, iceberg e frente oceânica.

Os obstáculos observados neste trabalho envolvem tanto a dificuldade de treinar imagens de look-like oriundas do gelo (a luz refletida ao radar nestes casos dificulta uma padronização) e também a pouca quantidade de imagens destas classes no banco de dados. É válido lembrar que a métrica de acurácia pode não ser adequada para avaliar o desempenho de modelos em bancos de dados desbalanceados [Grandini et al., 2020].

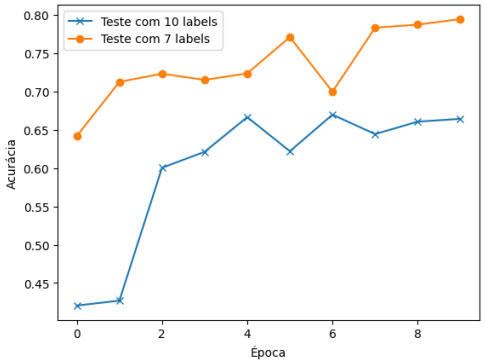
A co-ocorrência de valores de retroespalhamento do radar, similares as classes com manchas escuras também é um fator importante. Pois apesar das redes neurais apresentarem uma eficácia já comprovada na segmentação de alvos, testá-las como um sistema multiclasses tende a reduzir a precisão e a acurácia do modelo.

A solução proposta neste trabalho é retirar as três classes (gelo marinho, iceberg, e frente oceânica) do banco de dados para uma segunda rodada de testes já que, como explicado por [Conceição et al., 2021], a acurácia tende a aumentar com a redução do número de classes. Os resultados são expostos nos gráficos da Figura 4 a seguir para comparação.

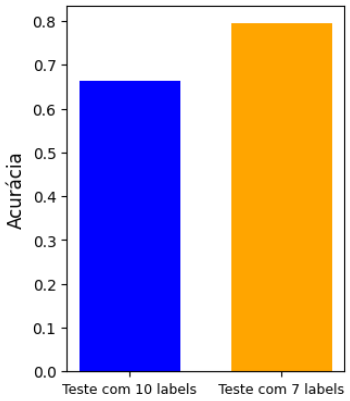
Figura 4 – Resultados dos testes com dez e sete classes

DOI: 10.59254/sbpo-2023-174938
http://live-proceedings.pantheonsite.io/p/174938

Acurácia de treinamento



Acurácia de teste



Fonte: os autores (2023)

Observando os valores de acurácia ao longo das 10 épocas de treinamento no gráfico da esquerda na Figura 4, é possível ver que a acurácia da experiência com sete classes aumenta gradualmente em média, o que sugere que o modelo está aprendendo e se ajustando bem aos dados de treinamento. Além disso, o valor da acurácia em relação aos dados de teste é de 0,7943, 13 pontos percentuais a mais para a experiência com apenas sete classes do que com todas as dez classes como visto no da direita da Figura 4.

Pode-se dizer que houve uma melhora considerável nos resultados da acurácia após a modificação no número de classes que deixou o banco de dados mais balanceado. O valor da perda também melhorou na segunda experiência; reduziu para 0,7479. A matriz de confusão apresentada na figura 5 mostra que as classes 3 e 9 são as que mais são confundidas pois apresentam a maior quantidade de imagens de testes classificadas como outras classes dentre os 20% de imagens para teste de cada classe.

Figura 5 – Matriz de Confusão

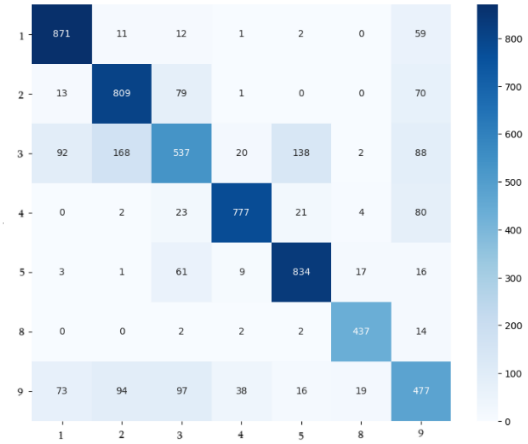
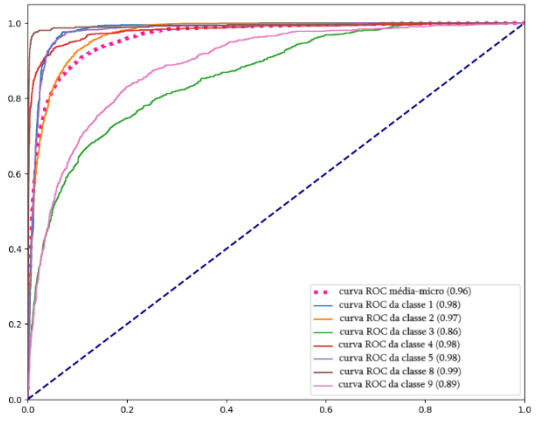


Figura 6 – Curva ROC



Fonte: os autores (2023)

A figura 6 expõe as curvas ROC das sete classes em estudo. A curva ROC é uma ferramenta gráfica utilizada também na análise de desempenho de classificadores. Quanto mais a área sob a curva se aproximar do valor 1, melhor o classificador. Novamente, a área sob curva ROC das classes 3 e 9 foram as menores quando comparadas às outras classes. No entanto, é notável que todas as classes possuem valores acima de 90%, exceto pelas duas classes já mencionadas que, contudo, apresentam valores ligeiramente menores que 90%.

Estes resultados demonstram que o modelo já é capaz de classificar look-alikes em uma de múltiplas classes. Consequentemente, ao combinar esta informação num outro modelo cuja finalidade seja analisar um banco de imagens mais abrangente, que contenha não apenas imagens

DOI: 10.59254/sbpo-2023-174938
http://live-proceedings.pantheonsite.io/p/174938

de look-alike, mas que simule um monitoramento real dos oceanos será possível uma detecção mais eficaz de vazamentos de óleo. Apesar disto, ainda existem oportunidades de ajustes que fariam os resultados do modelo em estudo serem melhores.

6. Conclusões

Com o objetivo de aumentar a capacidade de discernimento entre vazamentos reais e falsos positivos, foi construído um modelo de inteligência artificial capaz de diferenciar fenômenos oceanográficos presente em imagens de satélite. A incorporação desse modelo em um sistema de análise mais amplo de monitoramento do oceano terá um valor significativo, pois permitirá uma identificação rigorosa dos fenômenos, direcionando os esforços para lidar exclusivamente com vazamentos reais. Resultando num aprimoramento do gerenciamento de riscos e, portanto, numa redução das consequências adversas.

A indústria de óleo e gás tem aprimorado suas atividades de monitoramento dos oceanos por meio da inteligência artificial. O uso de técnicas de visão computacional associadas a modelos de aprendizagem de máquina tem permitido avanços na detecção automática de vazamentos de óleo no mar. A maior dificuldade na identificação destes vazamentos por computadores são outros fenômenos oceanográficos que também formam regiões escuras nas imagens de radar de satélite, os look-alikes.

A proposta deste trabalho é criar um modelo que seja capaz de classificar look-alikes usando uma rede neural convolucional. Aprendendo a classificar os vários tipos de look-alike, o modelo terá mais chances de diferenciá-los de um real vazamento de óleo e desta forma diminuirão as probabilidades de um falso-positivo.

Existem vários fenômenos oceanográficos que podem dar origem a um look-alike. Se fossem apenas dois, seria possível criar um modelo de classificação tradicional binária, ou seja, com apenas duas opções de classificação. Para o caso em estudo, onde se deseja classificar uma variável que pode assumir mais de dois valores distintos foi necessário construir um modelo de multiclassificação.

Foi construído um modelo de classificação multiclasse. As funções matemáticas e métodos escolhidos para o processamento dos dados no modelo são pertinentes para fazer uma multiclassificação. O banco de dados utilizado para treinamento do modelo foi o TenGeoP – SARwv, composto por imagens de radar de satélite com dez classes distintas de look-alike. Uma segunda leva de testes foi feito com o modelo considerando apenas sete destas classes.

Os resultados mostraram uma acurácia de quase 70% para o modelo de multiclassificação com as dez classes de look-alike. E o resultado desta métrica ficou cerca de 10% melhor após a remoção de três classes desbalanceadas em relação às outras no banco de dados. Contudo, os valores da função perda indicam que existem oportunidades de ajuste que podem tornar o modelo ainda mais preciso.

Agradecimentos

Os autores agradecem ao Programa de Recursos Humanos (PRH 38.1) administrado pela Agência Brasileira do Petróleo, Gás Natural e Biocombustíveis (ANP) e pela Financiadora de Estudos e Projetos (FINEP), 044819; ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), 310892/2022-8 e 308924/2021-5; à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), Código de Financiamento 001. Este trabalho foi parcialmente apoiado pelo Centro Gestor e Operacional do Sistema de Proteção da Amazônia – CENSIPAM.

Referências

Alpers, W., Holt, B., & Zeng, K. (2017). Oil spill detection by imaging radars: Challenges and pitfalls. *Remote Sensing of Environment*, *201*, 133–147. https://doi.org/10.1016/j.rse.2017.09.002

Alpers, W., & Hühnerfuss, H. (1989). The damping of ocean waves by surface films: A new look at an old problem. *Journal of Geophysical Research*, *94*(C5), 6251. https://doi.org/10.1029/JC094iC05p06251

DOI: 10.59254/sbpo-2023-174938
http://live-proceedings.pantheonsite.io/p/174938

Amri, E., Dardouillet, P., Benoit, A., Courteille, H., Bolon, P., Dubucq, D., & Credoz, A. (2022). Offshore Oil Slick Detection: From Photo-Interpreter to Explainable Multi-Modal Deep Learning Models Using SAR Images and Contextual Data. *Remote Sensing*, *14*(15). https://doi.org/10.3390/rs14153565

Atila, O., & Şengür, A. (2021). Attention guided 3D CNN-LSTM model for accurate speech based emotion recognition. *Applied Acoustics*, *182*. https://doi.org/10.1016/j.apacoust.2021.108260

Benelli, G., & Garzelli, A. ([s.d.]). Oil-spills detection in SAR images by fractal dimension estimation. *IEEE 1999 International Geoscience and Remote Sensing Symposium. IGARSS'99 (Cat. No.99CH36293)*, 218–220. https://doi.org/10.1109/IGARSS.1999.773452

Bhangale, U., Durbha, S. S., King, R. L., Younan, N. H., & Vatsavai, R. (2017). High performance GPU computing based approaches for oil spill detection from multi-temporal remote sensing data. *Remote Sensing of Environment*, *202*, 28–44. https://doi.org/10.1016/j.rse.2017.03.024

Brekke, C., & Solberg, A. H. S. (2005). Oil spill detection by satellite remote sensing. Em *Remote Sensing of Environment* (Vol. 95, Número 1, p. 1–13). https://doi.org/10.1016/j.rse.2004.11.015

Chaturvedi, S. K., Banerjee, S., & Lele, S. (2020). An assessment of oil spill detection using Sentinel 1 SAR-C images. *Journal of Ocean Engineering and Science*, *5*(2), 116–135. https://doi.org/10.1016/j.joes.2019.09.004

Conceição, M. R. A., de Mendonça, L. F. F., Lentini, C. A. D., da Cunha Lima, A. T., Lopes, J. M., de Vasconcelos, R. N., Gouveia, M. B., & Porsani, M. J. (2021). SAR Oil Spill Detection System through Random Forest Classifiers. *Remote Sensing*, *13*(11), 2044. https://doi.org/10.3390/rs13112044

de la Huz, R., Lastra, M., & López, J. (2019). Other Environmental Health Issues: Oil Spill. Em *Encyclopedia of Environmental Health* (p. 792–796). Elsevier. https://doi.org/10.1016/B978-0-12-409548-9.11156-X

Dhavalikar, A. S., & Choudhari, P. C. (2021). CLASSIFICATION OF OIL SPILLS AND LOOK-ALIKES FROM SAR IMAGES USING BAG OF VISUAL WORDS METHOD OF FEATURE EXTRACTION. *International Geoscience and Remote Sensing Symposium (IGARSS)*, 3428–3431. https://doi.org/10.1109/IGARSS47720.2021.9554307

Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning* . MIT Press. http://www.deeplearningbook.org

Grandini, M., Bagli, E., & Visani, G. (2020). *Metrics for Multi-Class Classification: an Overview*. http://arxiv.org/abs/2008.05756

Gulli, A., & Pal, S. (2017). *Deep Learning with Keras: Implementing deep learning models and neural networks with the power of Python*. Birmingham Mumbai: Packt Publishing.

Guo, Y., & Zhang, H. Z. (2014). Oil spill detection using synthetic aperture radar images and feature selection in shape space. *International Journal of Applied Earth Observation and Geoinformation*, *30*(1), 146–157. https://doi.org/10.1016/j.jag.2014.01.011

Jabbar, Z. S., Al-Neami, A. Q., Khawwam, A. A., & Salih, S. M. (2023). Liver fibrosis processing, multiclassification, and diagnosis based on hybrid machine learning approaches. *Indonesian Journal of Electrical Engineering and Computer Science*, *29*(3), 1614–1622. https://doi.org/10.11591/ijeecs.v29.i3.pp1614-1622

Litvinenko, V., Bowbrick, I., Naumov, I., & Zaitseva, Z. (2022). Global guidelines and requirements for professional competencies of natural resource extraction engineers: Implications for ESG principles and sustainable development goals. Em *Journal of Cleaner Production* (Vol. 338). Elsevier Ltd. https://doi.org/10.1016/j.jclepro.2022.130530

Liu, X., Zhang, Y., Zou, H., Wang, F., Cheng, X., Wu, W., Liu, X., & Li, Y. (2023). Multi-source knowledge graph reasoning for ocean oil spill detection from satellite SAR images. *International Journal of Applied Earth Observation and Geoinformation*, *116*. https://doi.org/10.1016/j.jag.2022.103153

Ma, H., Li, X., Liu, Q., Xingbo, X., Ji, C., & Zhao, C. (2020). Research on Identification Technology of Explosive Vibration Based on EEMD Energy Entropy and Multiclassification SVM. *Shock and Vibration*, *2020*. https://doi.org/10.1155/2020/7893925

Maior, C. B. S., Santana, J. M. M., Lins, I. D., & Moura, M. J. C. (2021). Convolutional neural network model based on radiological images to support COVID-19 diagnosis: Evaluating database biases. *PLOS ONE*, *16*(3), e0247839. https://doi.org/10.1371/journal.pone.0247839

Mohammed, F. E., Zghal, N. S., Aissa, D. Ben, & El-Gayar, M. M. (2022). Multiclassification Model of Histopathological Breast Cancer Based on Deep Neural Network. *2022 19th IEEE International*

DOI: 10.59254/sbpo-2023-174938
http://live-proceedings.pantheonsite.io/p/174938

Multi-Conference on Systems, Signals and Devices, SSD 2022, 1105–1111. https://doi.org/10.1109/SSD54932.2022.9955814

Negreiros, A. C. S. V. de, Lins, I. D., Maior, C. B. S., & Moura, M. J. das C. (2022). Oil spills characteristics, detection, and recovery methods: A systematic risk-based view. *Journal of Loss Prevention in the Process Industries*, *80*. https://doi.org/10.1016/j.jlp.2022.104912

Platonow, V. (2021). *Óleo que atingiu praias do Nordeste veio de petroleiro grego, diz PF*. Agência Brasil . https://agenciabrasil.ebc.com.br/geral/noticia/2021-12/oleo-que-atingiu-praias-do-nordeste-veio-de-petroleiro-grego-diz-pf#:~:text=As%20manchas%20de%20%C3%B3leo%20que,localidades%2C%20em%2011%20estados%20litor%C3%A2neos.

Raeisi, A., Akbarizadeh, G., & Mahmoudi, A. (2018). Combined Method of an Efficient Cuckoo Search Algorithm and Nonnegative Matrix Factorization of Different Zernike Moment Features for Discrimination between Oil Spills and Lookalikes in SAR Images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, *11*(11), 4193–4205. https://doi.org/10.1109/JSTARS.2018.2841503

Schistad Solberg, A. H., Storvik, G., Solberg, R., & Volden, E. (1999). Automatic detection of oil spills in ERS SAR images. *IEEE Transactions on Geoscience and Remote Sensing*, *37*(4), 1916–1924. https://doi.org/10.1109/36.774704

Shakil, M. H. (2021). Environmental, social and governance performance and financial risk: Moderating role of ESG controversies and board gender diversity. *Resources Policy*, *72*. https://doi.org/10.1016/j.resourpol.2021.102144

Singh, D., & Singh, B. (2020). Investigating the impact of data normalization on classification performance. *Applied Soft Computing*, *97*, 105524. https://doi.org/10.1016/j.asoc.2019.105524

Soares, M. O., & Rabelo, E. F. (2023). Severe ecological impacts caused by one of the worst orphan oil spills worldwide. *Marine Environmental Research*, *187*, 105936. https://doi.org/10.1016/j.marenvres.2023.105936

Topouzelis, K., Karathanassi, V., Pavlakis, P., & Rokos, D. (2007). Detection and discrimination between oil spills and look-alike phenomena through neural networks. *ISPRS Journal of Photogrammetry and Remote Sensing*, *62*(4), 264–270. https://doi.org/10.1016/j.isprsjprs.2007.05.003

Wang, C., Mouche, A., Tandeo, P., Stopa, J. E., Longépé, N., Erhard, G., Foster, R. C., Vandemark, D., & Chapron, B. (2019). A labelled ocean SAR imagery dataset of ten geophysical phenomena from Sentinel-1 wave mode. *Geoscience Data Journal*, *6*(2), 105–115. https://doi.org/10.1002/gdj3.73

Wu, J., Wei, G., Wang, Y., & Cai, J. (2023). Multifeature Fusion Classification Method for Adaptive Endoscopic Ultrasonography Tumor Image. *Ultrasound in Medicine and Biology*, *49*(4), 937–945. https://doi.org/10.1016/j.ultrasmedbio.2022.11.004

Wu, Y.-C., Lee, Y.-S., & Yang, J.-C. (2008). Robust and efficient multiclass SVM models for phrase pattern recognition. *Pattern Recognition*, *41*(9), 2874–2889. https://doi.org/10.1016/j.patcog.2008.02.010

Yang, Y. T., Fishbain, B., Hochbaum, D. S., Norman, E. B., & Swanberg, E. (2014). The supervised normalized cut method for detecting, classifying, and identifying special nuclear materials. *INFORMS Journal on Computing*, *26*(1), 45–58. https://doi.org/10.1287/ijoc.1120.0546

Yekeen, S. T., & Balogun, A. L. (2020). Advances in remote sensing technology, machine learning and deep learning for marine oil spill detection, prediction and vulnerability assessment. Em *Remote Sensing* (Vol. 12, Número 20, p. 1–31). MDPI AG. https://doi.org/10.3390/rs12203416

Yuan, X., Chen, J., Zhang, K., Wu, Y., & Yang, T. (2022). A Stable AI-Based Binary and Multiple Class Heart Disease Prediction Model for IoMT. *IEEE Transactions on Industrial Informatics*, *18*(3), 2032–2040. https://doi.org/10.1109/TII.2021.3098306

Zhang, B., Matchinski, E. J., Chen, B., Ye, X., Jing, L., & Lee, K. (2019). Marine Oil Spills—Oil Pollution, Sources and Effects. Em *World Seas: An Environmental Evaluation* (p. 391–406). Elsevier. https://doi.org/10.1016/B978-0-12-805052-1.00024-3

Zhang, M., Song, W., & Zhang, J. (2022). A Secure Clinical Diagnosis with Privacy-Preserving Multiclass Support Vector Machine in Clouds. *IEEE Systems Journal*, *16*(1), 67–78. https://doi.org/10.1109/JSYST.2020.3027758

Zhang, Z., Krawczyk, B., Garcìa, S., Rosales-Pérez, A., & Herrera, F. (2016). Empowering one-vs-one decomposition with ensemble learning for multi-class imbalanced data. *Knowledge-Based Systems*, *106*, 251–263. https://doi.org/10.1016/j.knosys.2016.05.048

DOI: 10.59254/sbpo-2023-174938
http://live-proceedings.pantheonsite.io/p/174938