

12º CONGRESSO BRASILEIRO DE PESQUISA E DESENVOLVIMENTO EM PETRÓLEO E GÁS



TÍTULO DO TRABALHO:

DETECÇÃO DE VAZAMENTO DE PETRÓLEO POR MEIO DE TÉCNICAS DE APRENDIZADO PROFUNDO

AUTORES:

Nicole Verza dos Santos, Isis Didier Lins, Luís Felipe Ferreira de Mendonça, Caio Bezerra Souto Maior, Márcio José das Chagas Moura

INSTITUIÇÃO:

Universidade Federal de Pernambuco

DETECÇÃO DE VAZAMENTO DE PETRÓLEO POR MEIO DE TÉCNICAS DE APRENDIZADO PROFUNDO

Resumo

Derramamentos de petróleo são eventos graves que envolvem a liberação não controlada de hidrocarbonetos líquidos, como petróleo bruto ou seus derivados, no ambiente, principalmente em áreas marinhas. Eles representam uma forma significativa de poluição ambiental, causando danos imediatos e de longo prazo aos ecossistemas marinhos, às praias e às comunidades costeiras. Nesse sentido, a detecção precoce e o alerta imediato desses derramamentos, por exemplo, a partir da combinação de conhecimento humano e tecnologia automatizada, tornam-se cruciais para atenuar os impactos ambientais, controlar a disseminação do óleo e garantir a segurança das vidas humanas e do ecossistema marinho. Considerando a necessidade de barreiras de segurança para prevenir acidentes, as técnicas de aprendizado profundo surgem como ferramentas computacionais promissoras para auxiliar os tomadores de decisão na resposta a derramamentos de óleo. Este estudo foca na detecção ágil de derramamentos de petróleo por meio de CNN e R-CNN. Para isso, é utilizado um banco de dados com 3718 imagens de radar distribuídas uniformemente com 1.859 ocorrências exibindo derramamento de óleo e 1.859 ocorrências exibindo a presença de oceano, em escala decibel, que após passar por pré-processamentos são utilizadas como entrada para o treinamento e teste dos modelos. Como resultados, tanto a CNN, como a R-CNN alcançaram uma acurácia de aproximadamente 94% com diferentes tipos de pré-processamentos, além outras métricas que foram exploradas. Com isso, o artigo permite uma comparação de dois modelos do aprendizado profundo com o intuito de uma detecção mais precisa da presença ou não do óleo para mitigação de consequências.

Palavras-chave: Derramamento de Petróleo, Detecção Automatizada, Aprendizagem Profunda.

Abstract

Oil spills are severe events involving the uncontrolled release of liquid hydrocarbons, such as crude oil or its derivatives, into the environment, primarily in marine areas. They represent a significant form of environmental pollution, causing both immediate and long-term damage to marine ecosystems, beaches, and coastal communities. In this context, early detection and immediate alert of these spills, for example through the combination of human knowledge and automated technology, become crucial for mitigating environmental impacts, controlling oil spread, and ensuring the safety of human lives and marine ecosystems. Given the need for safety barriers to prevent accidents, deep learning techniques emerge as promising computational tools to assist decision-makers in responding to oil spills. This study focuses on the agile detection of oil spills using CNN and R-CNN models. A dataset of 3,718 radar images, evenly distributed with 1,859 occurrences of oil spills and 1,859 occurrences of ocean presence, in decibel scale, is used. After preprocessing, these images serve as input for training and testing the models. As a result, both the CNN and R-CNN achieved an accuracy of approximately 94% with different types of preprocessing, along with other metrics that were explored. Thus, the paper provides a comparison of two deep learning models aimed at more precise detection of oil presence for mitigation of consequences.

Keywords: Oil Spill, Automated Detection, Deep Learning.

Introdução

Os vazamentos de óleo referem-se à liberação descontrolada de hidrocarbonetos líquidos, como o petróleo bruto ou seus derivados, no meio ambiente, particularmente em áreas marinhas. Esses incidentes geralmente se originam de descargas ilícitas de lastro e resíduos oleosos durante a limpeza de petroleiros e tanques de navios, conforme mencionado por Briggs e Briggs (2018). Os vazamentos de óleo representam uma forma grave de poluição ambiental, resultando em impactos negativos imediatos e a longo prazo.

Os vazamentos de óleo também têm implicações econômicas significativas, resultando em custos substanciais para as empresas envolvidas. A limpeza e recuperação das áreas afetadas exigem recursos consideráveis, enquanto multas governamentais impostas pela poluição aumentam a pressão financeira, segundo Singh, Bhardwaj, Arya e Khatri (2020). Além disso, é necessário considerar tanto os custos privados quanto os custos externos associados aos vazamentos de óleo. Os custos privados incluem danos à plataforma de petróleo, custos de contenção e limpeza, perda de óleo e despesas legais. Os custos externos abrangem perda de vidas e ferimentos de trabalhadores, custos de contenção e limpeza suportados por agências governamentais, danos à infraestrutura pública, perda de renda para empresas afetadas, mudanças no comportamento do consumidor e danos aos recursos naturais. De acordo com Cohen (2010), quando esses custos foram totalizados no acidente da Deepwater Horizon, com cerca de 80 mil toneladas de resíduos, eles chegaram a 40 bilhões de dólares. Esses custos enfatizam a importância de implementar sistemas automatizados de detecção de vazamentos de óleo. Além disso, as comunidades locais dependentes de atividades como pesca e turismo são fortemente afetadas, e a saúde humana pode ser comprometida devido à exposição a substâncias tóxicas presentes no óleo.

A gravidade desses riscos é agravada pela resposta lenta a desastres de vazamento de óleo. Uma resposta rápida aos vazamentos reduz a propagação indiscriminada e as prováveis consequências. Portanto, a detecção precoce e o alerta imediato de vazamentos de óleo tornam-se cruciais para mitigar tais consequências, especialmente considerando desastres passados, como o ocorrido em 2010 na costa do Golfo do México e outros, como o caso do petroleiro Sanchi na China em 2018, que resultou no derramamento de cerca de 113.000 toneladas, evidenciado pelo ITOPF (2023).

Considerando a necessidade de barreiras de segurança para prevenir acidentes, as técnicas de aprendizado profundo (DL) surgem como ferramentas computacionais promissoras para auxiliar os tomadores de decisão na resposta a vazamentos de óleo. Algoritmos de aprendizado profundo, conforme destacado por Yekeen et al. (2020), utilizam múltiplas camadas ocultas que permitem um nível elevado de abstração, predição, generalização e transferibilidade de dados. Além disso, como apresentado por Temitope Yekeen & Balogun (2020), a forte extração de características e a capacidade de aprendizado autônomo dos modelos de aprendizado profundo aumentam sua precisão de detecção dos vazamentos do óleo.

Entre esses modelos, a rede neural convolucional (CNN) é um dos algoritmos mais representativos. As CNNs são particularmente eficazes na análise de dados espaciais, como imagens, devido à sua capacidade de extrair características hierárquicas e de identificar padrões complexos com alta precisão. Segundo Yang et al. (2022), as CNNs alcançaram resultados bons na classificação de imagens com óleo, mostrando uma precisão maior em comparação com outros métodos de classificação.


A R-CNN é uma extensão das CNNs que combina a capacidade de extração de características das CNNs com uma abordagem de detecção de objetos. De acordo com Girshick et al. (2014), a R-CNN melhora significativamente a precisão da detecção de objetos em imagens ao utilizar uma abordagem de proposta de região, que identifica e refina regiões de interesse dentro de uma imagem antes de aplicar a rede neural para classificação e segmentação no contexto dos vazamentos de óleo.

Este estudo, portanto, foca na detecção ágil de vazamentos de óleo, realizando testes e treinamentos com os modelos de aprendizado profundo CNN e R-CNN. O objetivo é fornecer uma análise comparativa desses modelos, com a finalidade de mitigar os impactos ambientais, sociais e econômicos causados pelos desastres relacionados a vazamentos de óleo.

Metodologia

Na metodologia utilizada, conforme ilustrado na Figura 1, foram estabelecidas três etapas principais: pré-processamento de imagens, aplicação de modelos preditivos e, conseqüentemente, classificação de imagens. Abaixo, cada etapa utilizada no trabalho é detalhada.


Figura 1 - Fluxograma da Metodologia



Fonte: Os autores

1. Base de dados

Figura 2: Imagens e suas máscaras.



Fonte: Os autores

O banco de dados utilizado é composto por 3718 imagens, distribuídas uniformemente com 1859 instâncias exibindo vazamento de óleo e outras classes, e 1859 instâncias exibindo a presença de oceano e outras classes. O banco de dados foi desenvolvido e disponibilizado pela Universidade Federal da Bahia (UFBA) como parte da pesquisa intitulada “Desenvolvimento de um sistema autônomo para detecção e monitoramento de óleo no oceano”. As imagens estão em escala de cinza, contendo apenas um canal de cor, no formato 64x64 e na escala de decibéis.

A escala decibel (dB) é uma unidade logarítmica usada para medir a intensidade de um sinal em relação a um valor de referência. Originalmente, foi desenvolvida para medir a intensidade do som, mas sua aplicação se expandiu para outras áreas, incluindo processamento de imagens, eletrônica e

telecomunicações. Em imagens de satélite e radar, os dados em escala decibel representam a intensidade do sinal refletido de volta para o sensor, após interagir com a superfície terrestre.

O uso de imagens em escala decibel é vantajoso principalmente porque imagens de satélite e radar frequentemente capturam dados com ampla variação de intensidade. A escala ajuda a comprimir essas variações em uma faixa mais manejável, o que facilita o processamento e a interpretação dos dados. Além disso, a escala decibel é eficaz para destacar mudanças significativas em relação a um ponto de referência, permitindo identificar padrões importantes enquanto reduz o impacto de variações menores ou ruídos nos dados. Isso melhora a precisão das análises realizadas com base nessas imagens.

2. Pré-processamento

Neste estudo, o pré-processamento envolve três etapas: normalização dos dados, PCA (Análise de Componentes Principais) e padronização. A normalização dos dados é a única etapa obrigatória, e nos testes conduzidos foram realizados treinamentos tanto com quanto sem PCA, assim como com e sem padronização. Isso permite explorar diferentes abordagens e avaliar como influenciam o desempenho do modelo.

2.1. Normalização

A normalização dos dados é uma etapa importante no processamento da informação, especialmente nos campos da análise de dados e aprendizado de máquina. Métodos como a Normalização Min-Max são amplamente utilizados para escalar dados dentro de intervalos específicos. No entanto, neste estudo, optou-se por normalizar os dados usando o menor valor encontrado na escala de decibéis como divisor para todo o conjunto, visando garantir que o conjunto de dados fique restrito ao intervalo entre 0 e 1.

2.2. Análise dos componentes principais (PCA)

A Análise de Componentes Principais (PCA), conforme descrito por Jolliffe (2002), visa reduzir a dimensionalidade de um conjunto de dados com muitas variáveis inter-relacionadas. O propósito é conservar o máximo da variação presente nos dados. Isso é alcançado ao transformar as variáveis em um novo conjunto, os componentes principais (PCs), que são não correlacionados e organizados de maneira que os primeiros componentes retenham a maior parte da variação das variáveis originais. Segundo Dunteman (1989), um conjunto reduzido de variáveis não correlacionadas é muito mais fácil de compreender e usar em análises posteriores do que um conjunto maior de variáveis correlacionadas.

2.3. Padronização

A padronização é uma técnica de pré-processamento em aprendizado de máquina destinada a padronizar as características de um conjunto de dados. Essa padronização é realizada subtraindo a média e dividindo pelo desvio padrão. Essa técnica é amplamente utilizada para garantir que diferentes características tenham escalas comparáveis, o que é especialmente útil em algoritmos sensíveis à escala dos dados, como aqueles baseados em distância (por exemplo, k-means) ou que envolvem gradientes (por exemplo, redes neurais). Todos os dados foram padronizados utilizando a função `StandardScaler` da biblioteca `Sklearn` na linguagem `Python`.


3. Modelos Preditivos

3.1. Convolutional Neural Network (CNN)

De acordo com Li et al. (2022), as redes neurais convolucionais são uma das arquiteturas mais importantes na área de aprendizado profundo. Essas redes neurais artificiais são inspiradas no funcionamento do córtex visual humano. Como modelos de aprendizado profundo, as CNNs têm a capacidade de extrair características dos dados de forma automática através de suas camadas. Nesse contexto, as camadas de convolução são fundamentais, pois aplicam filtros que funcionam como detectores de características em áreas locais das imagens. Esses filtros são essenciais para identificar padrões específicos, como bordas, texturas e formas, que são cruciais para a tarefa de reconhecimento de padrões em imagens. Durante o treinamento, os pesos desses filtros são ajustados para otimizar a habilidade da rede em identificar padrões relevantes, melhorando assim seu desempenho nas tarefas atribuídas.

A arquitetura da CNN construída nesse trabalho foi representado na Figura 3.

Figura 3- Arquitetura da CNN



Fonte: Os autores


3.2. Region-based Convolutional Neural Network (R-CNN)

A R-CNN é uma arquitetura de rede neural profunda projetada para a tarefa de detecção de objetos em imagens. Introduzida por Ross Girshick em 2014, a R-CNN divide a imagem em várias regiões propostas e, em seguida, utiliza uma CNN para extrair recursos dessas regiões. Cada região é classificada e refinada para determinar se contém um objeto de interesse.

A R-CNN divide a imagem de entrada em várias "propostas de regiões" ou "candidatos a regiões", geradas por métodos externos como o Selective Search ou EdgeBoxes. Cada região proposta é redimensionada e processada por uma CNN pré-treinada para extrair características detalhadas. Essas características são usadas para classificar as regiões e ajustar as caixas delimitadoras, determinando a localização e a classe dos objetos na imagem. A arquitetura usada nesse trabalho pode ser visualizada na Figura 4.

A arquitetura da R-CNN desenvolvida nesse trabalho pode ser visualizado na Figura 4.

Figura 4- Arquitetura da R-CNN



Fonte: Os autores

Resultados e Discussão

Os resultados obtidos após 100 épocas são apresentados na Tabela 1. Essa tabela resume as melhores métricas de desempenho de cada modelo, incluindo acurácia, precisão, pontuação F1, recall, função perda (loss) e tempo gasto por época.

No contexto de detecção de derrames, uma das principais métricas a analisar é a recall, devido ao fato de os falsos negativos serem considerados mais prejudiciais do que os falsos positivos, uma vez que a falha na detecção de um derrame pode levar a graves consequências ambientais e econômicas. No entanto, é importante realizar uma análise abrangente que considere todas as métricas disponíveis.

Tabela 1: Desempenho dos modelos

Técnicas de Pré-Processamento	Modelo	Acurácia	Precisão	Recall	F1-Score	Loss	Tempo (ms/época)
Sem PP	CNN	0.9274	0.9084	0.9593	0.9332	0.720	35
Sem PP	R-CNN	0.8924	0.8930	0.8884	0.8876	0.892	210
PCA	CNN	0.9207	0.8957	0.9618	0.9276	0.498	30
PCA	R-CNN	0.8672	0.8737	0.8508	0.8471	0.371	290
STD	CNN	0.9261	0.8957	0.9618	0.9276	0.498	31
STD	R-CNN	0.9408	0.9428	0.9408	0.9406	0.248	263
PCA+STD	CNN	0.9422	0.9289	0.9644	0.9463	0.489	34
PCA+STD	R-CNN	0.9435	0.9440	0.9435	0.9434	0.222	274

Fonte: Os autores

O uso da R-CNN foi considerado ao pensar na identificação da mancha de petróleo como um objeto específico dentro de uma imagem maior. Mesmo sendo utilizada frequentemente para detecção de múltiplos objetos e não uma classificação binária, ela apresentou um ótimo desempenho na detecção da presença ou não do óleo nas imagens testadas. No entanto, é computacionalmente intensiva e exigiu mais tempo para treinamento, comparado com uma CNN simples.

Podemos observar também que a CNN, já muito usada na literatura para esse contexto, apresenta um desempenho muito satisfatório, o que já era esperado devido a sua capacidade de extrair características relevantes de imagens e realizar tarefas complexas de reconhecimento visual. A eficácia da CNN na classificação de imagens pode ser atribuída à sua habilidade em aprender e identificar padrões espaciais em diferentes níveis de abstração.

A análise dos resultados na Tabela 1 mostra que as técnicas de pré-processamento combinadas (PCA+STD) melhoraram o desempenho dos modelos em geral. Especificamente, a CNN com PCA+STD alcançou as melhores métricas de recall e F1-score, o que é importante para a detecção de derrames de óleo, onde a minimização de falsos negativos é fundamental. Isso confirma a hipótese de que técnicas de pré-processamento e modelos de aprendizagem profunda, como vistos nesse estudo, podem oferecer vantagens significativas em cenários de detecção de vazamentos de petróleo.

Conclusões

O estudo explorou modelos de deep learning para detecção de vazamentos de óleo, utilizando diferentes tipos de pré-processamentos, se mostrando eficaz como método de apoio para a detecção rápida e automatizada dessas ocorrências.

Ambos os modelos apresentados desempenharam um ótimo desempenho na classificação binária da presença de óleo e não óleo. No entanto, o modelo R-CNN requer um tempo de treinamento significativamente maior em comparação com a CNN, que se mostrou eficiente em um tempo mais curto.

Agradecimentos

Os autores agradecem às seguintes agências brasileiras de fomento à pesquisa pelo apoio financeiro: Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq); Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), Código de Financiamento 001; Programa de Recursos Humanos 38.1 (PRH 38.1) intitulado Análise de Risco e Modelagem Ambiental na Exploração, Desenvolvimento e Produção de Petróleo e Gás, financiado pela Agência Nacional de Petróleo, Gás Natural e Biocombustíveis (ANP) e gerenciado pela Financiadora de Estudos e Projetos (FINEP), 044819.

Referências Bibliográficas

- Briggs, I. L., & Briggs, B. C. (2018). Petroleum industry activities and human health. In *The Political Ecology of Oil and Gas Activities in the Nigerian Aquatic Ecosystem* (pp. 143–147). Elsevier. <http://dx.doi.org/10.1016/b978-0-12-809399-3.00010-0>
- Cohen, M., 2010. *A Taxonomy of Oil Spill Costs: What are the Likely Costs of the Deepwater Horizon Spill?*, Resources for the Future. United States of America. Retrieved from <https://policycommons.net/artifacts/1947722/a-taxonomy-of-oil-spill-costs/2699491/> on 21 Feb 2024. CID: 20.500.12592/fvgrq8.
- Dunteman, G. H. (1989). *Principal components analysis* (p. 7). SAGE.
- Géron, A. (2022). *Hands-On machine learning with Scikit-Learn, Keras, and TensorFlow*. “O’Reilly Media, Inc.”
- Girshick, R., Donahue, J., Darrell, T., Malik, J., & Mercan, E. (2014). R-CNN for object detection. In *IEEE Conference*.
- ITOPF. (2023). *Oil Tanker Spill Statistics 2023*. International Tanker Owners Pollution Federation.
- Jolliffe, I. T. (2002). *Principal component analysis* (p. 1). Springer Science & Business Media.
- Singh, H., Bhardwaj, N., Arya, S. K., & Khatri, M. (2020). Environmental impacts of oil spills and their remediation by magnetic nanomaterials. *Environmental Nanotechnology, Monitoring & Management*, 14, 100305. <https://doi.org/10.1016/j.enmm.2020.100305>
- Temitope Yekeen, S., & Balogun, A. L. (2020). Advances in remote sensing technology, machine learning and deep learning for marine oil spill detection, prediction and vulnerability assessment. *Remote Sensing*, 12(20), 3416.
- Z. Li, F. Liu, W. Yang, S. Peng and J. Zhou. (2022). A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects. In *IEEE Transactions on Neural Networks and Learning Systems*, vol. 33, no. 12, pp. 6999-7019, Dec. 2022, doi: 10.1109/TNNLS.2021.3084827.
- Yekeen, S. T., Balogun, A. L., & Yusof, K. B. W. (2020). A novel deep learning instance segmentation model for automated marine oil spill detection. *ISPRS Journal of Photogrammetry and Remote Sensing*, 167, 190-200.
- Yang, J., Ma, Y., Hu, Y., Jiang, Z., Zhang, J., Wan, J., & Li, Z. (2022). Decision fusion of deep learning and shallow learning for marine oil spill detection. *Remote Sensing*, 14(3), 666.