



Detecção de vazamento de petróleo no mar utilizando *Deep Learning* em imagens hiperespectrais

Palavras-Chave: Petróleo, Sensoriamento Remoto, Deep Learning

Autores/as:

Thassia Pine Gondek, IG/UNICAMP

Prof. Dr. Carlos Roberto de Souza Filho (orientador), IG/UNICAMP

1. INTRODUÇÃO

Nas últimas décadas, o número de derramamentos de petróleo tem sido reduzido devido ao desenvolvimento de novas tecnologias de controle. Uma das contramedidas mais eficazes para atenuar os danos ambientais por derramamento de petróleo é detectar e qualificar a mancha de óleo, antes que o derramamento atinja grandes proporções. O sensoriamento remoto vem sendo utilizado como um excelente meio de monitoramento para esse fim. Sensores hiperespectrais e multiespectrais de alta resolução espectral (ASTER, WV-3) têm a capacidade de observar grandes áreas dos oceanos e obter informações como espessura e tipo de óleo (e.g., com graus API variados) (Lammoglia & Souza Filho, 2011, 2012; Pelta et.al, 2019), oferecendo substancial vantagem em relação a outros métodos de detecção e caracterização de petróleo no mar.

Os sensores hiperespectrais operam principalmente na região do espectro visível-infravermelho próximo (400-1000 nm) e infravermelho de ondas curtas (1000-2500nm), permitindo, assim, o estudo das propriedades químicas e físicas dos óleos a partir de absorções espectrais geradas por vibrações moleculares.

Devido ao grande número e intervalo nanométrico das bandas espectrais envolvidas, as imagens hiperespectrais permitem obter informações como a espessura e propriedades qualitativas (e.g. composição química) da mancha de óleo, algo que não é possível utilizando-se sensores comumente

utilizados para esse objetivo, como imagens SAR (Synthetic Aperture Radar) (Al-Ruzouq et. al, 2019 Lammoglia & Souza Filho, 2011).

Um dos desafios em lidar com imagens hiperespectrais é sua alta dimensão, ou seja, o grande número de bandas. Desta forma, para treinar um modelo do tipo *machine learning* é necessário pré-processar as imagens a fim de reduzir o ruído irrelevante ao processo de treinamento e realçar as feições de interesse, diminuindo incertezas do modelo (Pelta et. al, 2019).

Para minimizar os ruídos e ampliar o sinal de feições espectrais características do óleo, algumas técnicas têm demonstrado sucesso, como o filtro Savitzky-Golay (Scafutto & Souza Filho 2016) e a transformação *Wavelets* (Pabón & Souza Filho; 2019)

2. OBJETIVOS

Neste trabalho, as bibliotecas PyWavelets, Rasterio e SciPy, escritas na linguagem de programação Python, serão utilizadas para extrair informações de imagens hiperespectrais sobre tanques com solução de água salina contendo filmes de petróleo de diferentes espessuras (Figura 1). O objetivo é identificar as características espectrais de absorção do óleo, reduzir ruídos, realçar os principais picos de absorção do óleo e, futuramente, utilizar algoritmos de redes neurais convolucionais (CNN) para identificar as manchas de óleo e diferenciar óleos mais espessos dos mais finos vazados nos tanques.

3. METODOLOGIA

A primeira etapa do projeto consistiu na seleção de imagens geradas por experimentos de campo coordenados pelo orientador da pesquisa. Essas imagens simulam vazamentos de petróleo em tanques com solução salina contendo filmes de petróleo de diferentes espessuras. O sistema hiperespectral utilizado para obter as imagens foi a *HySpex Mjolnir VS-620*, que possui duas câmeras: a V-1240, abrangendo a região do VNIR (970-2500 nm) com resolução espectral de 3,0 nm e resolução espacial de 1240 pixels; e a S-620, cobrindo a região do SWIR (970-2500 nm) com resolução espectral de 5,1 nm e resolução espacial de 620 pixels. O sistema opera a bordo do drone BFD XQ-1400S. Baseando-se no trabalho de Scafutto & Souza Filho (2016), como parte do pré-processamento foi aplicado o filtro de Savitzky-Golay. Esse método é utilizado para reduzir ruídos e a partir de uma convolução linear não-ponderada baseada em um ajuste de polinômios de mínimos quadrados (Savitzky & Golay, 1969). O filtro foi aplicado utilizando a biblioteca *SciPy* do Python (Virtanen, 2020).

Posteriormente, seguindo Pabón & Souza Filho (2019), foi aplicada uma transformação Wavelet contínua utilizando uma wavelet derivada de

Gaussiana de 2.^a ordem. O filtro foi aplicado utilizando a biblioteca *PyWavelets* do Python (Lee, 2019).

A transformada de *Wavelet* Contínua (CWT) é uma ferramenta de análise onde o sinal é decomposto em diferentes escalas, separando amplitudes de altas (em geral, ruído) e baixa frequência presentes no sinal, o que visa reduzir ruídos e ampliar o sinal de feições características do óleo. A *Wavelet* escolhida para essa análise foi a derivada de 2.^a ordem da gaussiana:

$$\varphi(t) = C \cdot 2^{-t^2}, \text{ onde } C \text{ é uma constante.}$$

(Lee, 2019)

O fluxo de trabalho utilizado até o momento é explicado na Figura 1. O pré-processamento foi aplicado em toda a imagem. A assinatura de um pixel foi extraída para ilustrar a característica do espectro do óleo em reflectância. Os algoritmos de *deep learning* ainda estão em fase de testes e validação.

4. RESULTADOS E DISCUSSÃO

A primeira etapa do pré-processamento com o filtro Savitzky-Golay conforme Ruffin & King (1999) explicitam, deve remover picos de ruído, tornando as feições de absorção espectral mais destacadas.

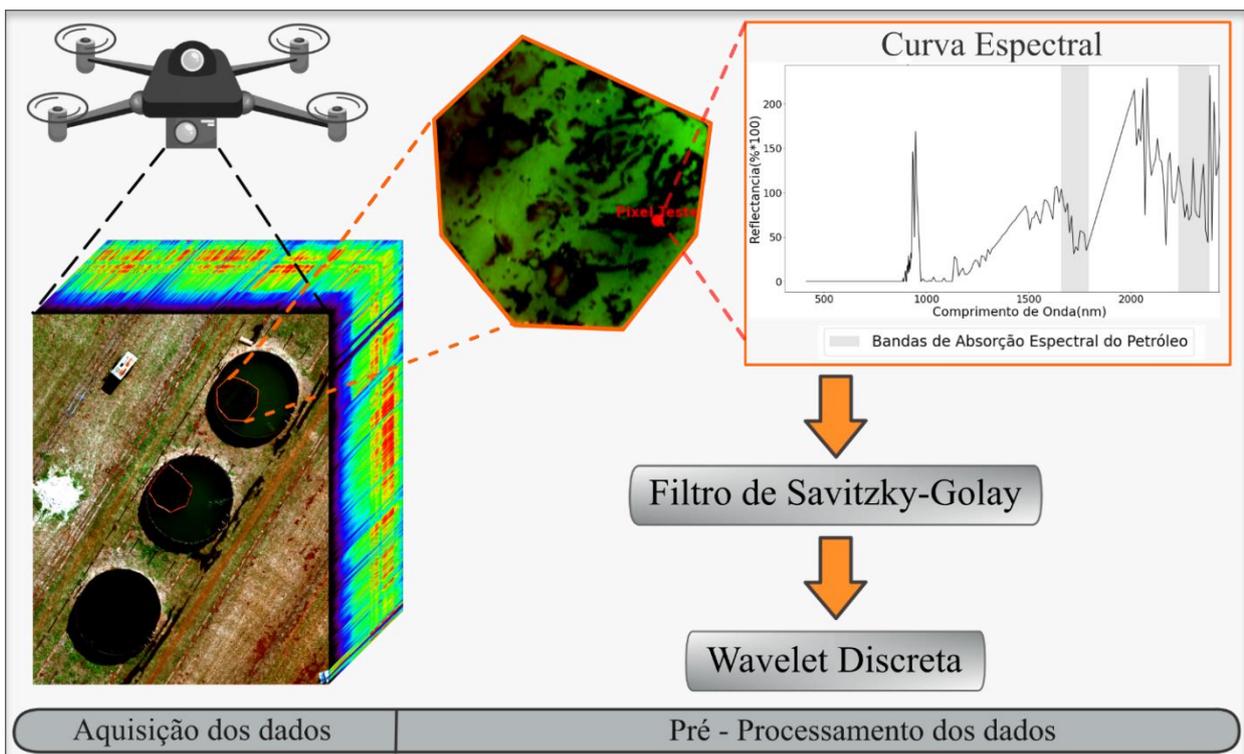


Figura 1. Estrutura da metodologia utilizada.

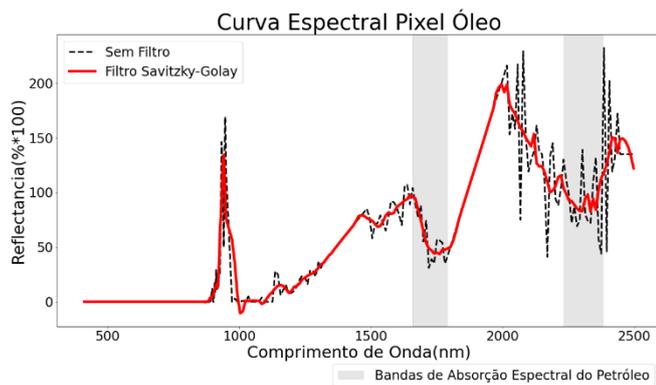


Figura 2. Resultado atingido com o filtro de Savitzky-Golay.

No gráfico na figura 2 é possível observar que o resultado do filtro atingiu o esperado. A curva em vermelho, filtrada, mostra que os picos no espectro relacionados a ruídos digitais, foram praticamente eliminados. Por outro lado, as feições de absorção mais importantes do óleo foram realçadas, em particular aquelas centradas entre 1660 – 1790 nm e 2233 – 2380 nm (Pabón & Souza Filho, 2019), indicadas em faixas cinzas.

Para a análise de Wavelet, (Figura 3), o espectro foi decomposto em oito coeficientes. O coeficiente 0 foi descartado por conter apenas os ruídos do sinal original. Os coeficientes 1, 2 e 3 foram escolhidos por destacar as feições de absorção do óleo. Os coeficientes 4, 5, 6 e 7 foram descartados pois as feições estão relacionados ao albedo (continuum) da superfície imageada.

Coeficientes CWT do VNIR-SWIR (350-2500 nm)

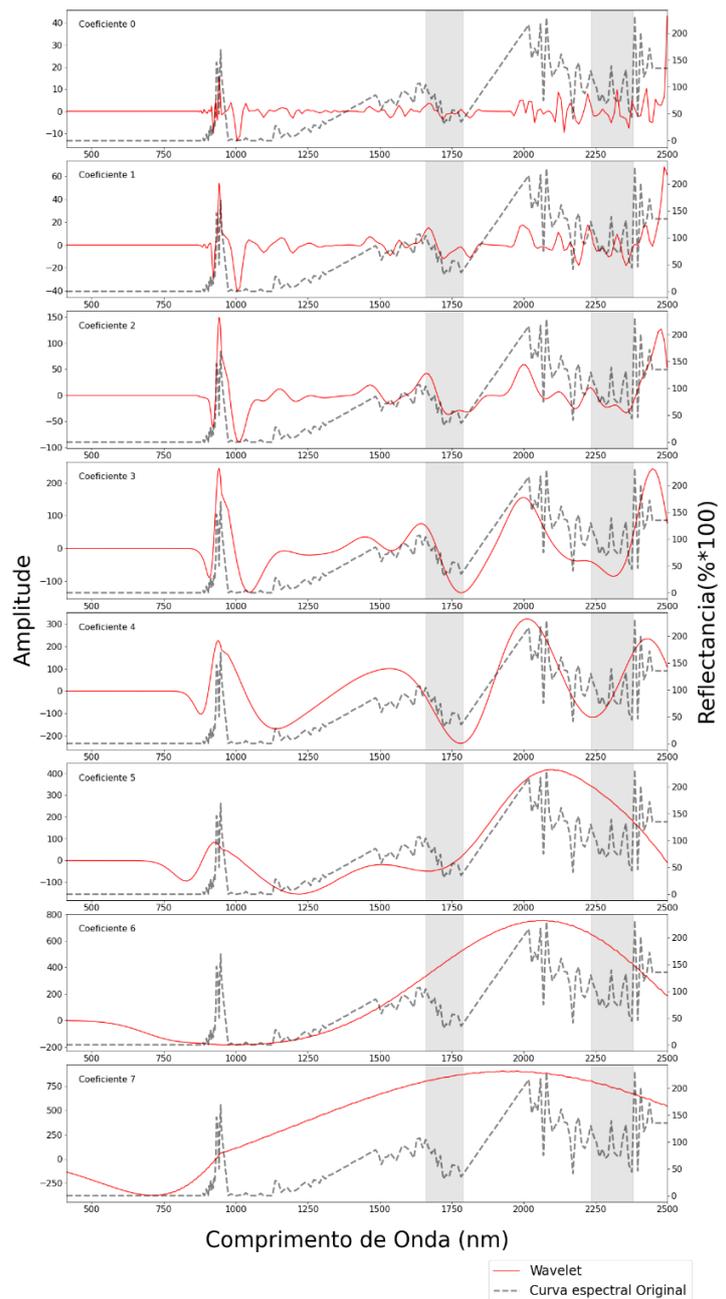


Figura 3. Coeficientes resultantes da análise de Wavelet

Os coeficientes 1, 2 e 3 foram somados (figura 4) para compor a curva de amplitude similar a curva de reflectância original, com uma redução significativa dos ruídos e realce das feições de interesse.

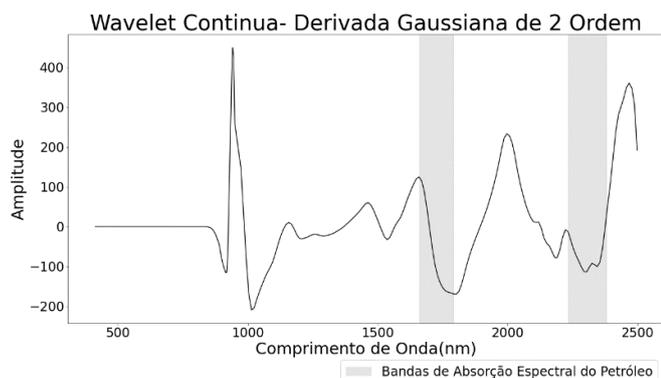


Figura 4. Curva resultante da soma da Wavelet Contínua.

5. CONCLUSÃO

Os resultados parciais obtidos na pesquisa mostram que a etapa de pré-processamento dos dados foi exitosa. As principais feições de absorção de óleo foram amplificadas e o ruído minimizado. O método foi aplicado para toda a imagem e passará por testes futuros de consistência.

6. TRABALHOS FUTUROS

Os próximos passos do projeto serão focados na modelagem com algoritmos de redes neurais convolucionais (CNN) visando a segmentação das manchas de óleo e separação entre óleos mais espessos e mais finos vazados nos tanques.

Os modelos de Redes Neurais Convolucionais (CNN) geram um modelo preditivo a fim identificar a presença de óleo nas imagens coletadas. CCNs são construídas utilizando um sistema de multicamadas de redes neurais, onde cada camada nos permite extrair uma característica diferente da imagem. Isso nos permite analisar imagens mais complexas e gerar modelos de classificação mais precisos. Este modelo foi escolhido pois estudos recentes mostram uma maior eficácia das CNN, quando comparados a outros métodos de classificação, para a identificação de petróleo no mar (Liu, 2019; Yang et. al, 2022).

REFERÊNCIAS

- AL-RUZOUQ, R. et al. **Sensors, Features, and Machine Learning for Oil Spill Detection and Monitoring: A Review.** *Remote Sensing*, v. 12, n. 20, p. 3338, 13 out. 2020.
- LAMMOGLIA, T.; SOUZA FILHO, C. R. **Mapping and characterization of the API gravity of offshore hydrocarbon seepages using multispectral ASTER data.** *Remote Sensing of Environment*, v. 123, p. 381–389, ago. 2012.
- LAMMOGLIA, T.; SOUZA FILHO, C. R. **Spectroscopic characterization of oils yielded from Brazilian offshore basins: Potential applications of remote sensing.** *Remote Sensing of Environment*, v. 115, n. 10, p. 2525–2535, out. 2011.
- LEE, G. R., GOMMERS, R., WASILEWSKI, F., WOHLFAHRT, K. (2019). **PyWavelets: A Python package for wavelet analysis.** *Journal of Open Source Software*, 4(36), 1237.
- LIU, B. et al. **A Spectral Feature Based Convolutional Neural Network for Classification of Sea Surface Oil Spill.** *ISPRS International Journal of Geo-Information*, v. 8, n. 4, p. 160, 27 mar. 2019.
- PABÓN, R. E. C., SOUZA FILHO, C. R. **Crude Oil Spectral Signatures and Empirical Models to Derive API Gravity.** *Fuel*, vol. 237, fevereiro de 2019, p. 1119–31.
- PELTA, R.; CARMON, N.; BEN-DOR, E. A machine learning approach to detect crude oil contamination in a real scenario using hyperspectral remote sensing. **International Journal of Applied Earth Observation and Geoinformation**, v. 82, out. 2019, p. 101901–101016.
- RUFFIN, C., KING, R. L. **The Analysis of Hyperspectral Data Using Savitzky-Golay Filtering - Theoretical Basis (Part 1).** *IEEE 1999 International Geoscience and Remote Sensing Symposium*, julho de 1999, doi: 10.1109/IGARSS.1999.774430.
- SAVITZKY, A.; GOLAY, M. J. E. **Smoothing and differentiation of data by simplified least squares procedures.** *Analytical Chemistry*, v. 36, n. 8, p. 1627–1639, 1964.
- SCAFUTTO, R. D. M., SOUZA FILHO, C. R. **Quantitative Characterization of Crude Oils and Fuels in Mineral Substrates Using Reflectance Spectroscopy: Implications for Remote Sensing.** *International Journal of Applied Earth Observation and Geoinformation*, vol. 50, agosto de 2016, p. 221–42.

VIRTANEN, P. et al. **SciPy 1.0: Fundamental Algorithms for Scientific Computing in Python**. Nature Methods, v. 17, n. 3, p. 261-272, 2020.

YANG, J. et al. **Decision Fusion of Deep Learning and Shallow Learning for Marine Oil Spill Detection**. Remote Sensing, v. 14, n. 3, p. 666, 30 jan. 2022.