

DESENVOLVIMENTO E APLICAÇÃO DE MODELOS PREDITIVOS PARA DISTINGUIR SEEPAGE SLICKS DE OIL SPILLS EM IMAGENS SAR DA SUPERFÍCIE DO MAR: TRANSFERÊNCIA DE APRENDIZAGEM ENTRE O GOLFO DO MÉXICO E A MARGEM CONTINENTAL BRASILEIRA

Patrícia Carneiro Genovez¹, Francisco Fábio de Araújo Ponte¹, Ítalo de Oliveira Matias¹, Sarah Barrón Torres¹, Carlos Henrique Beisl², Gil Márcio Avellino Silva³ e Fernando Pellon de Miranda³

¹Laboratório de Engenharia de Software: Pontifícia Universidade Católica (PUC-Rio). Rua Marquês de São Vicente, 225, Gávea, Rio de Janeiro, 22451-900, Brasil: {genovezp; fabioponte; italo.matias; sarah.barron}@les.inf.puc-rio.br; ²Geoespaço: Rua Miguel de Farias, 92, Icaraí, Niterói, Rio de Janeiro, 24220-002 beisl@geospatialpetroleum.com; ³Centro de Pesquisas, Desenvolvimento e Inovação Leopoldo Américo Miguez de Mello (CENPES/Petrobras). Av. Horácio Macedo, 950, Cidade Universitária, Universidade Federal do Rio de Janeiro, 21941-915, Brasil: {fmiranda; gilmarcio}@petrobras.com.br

RESUMO

Manchas de óleo naturais ou antrópicas induzem a atenuação da rugosidade da superfície do mar, sendo igualmente detectadas como alvos escuros por Radares de Abertura Sintética (SAR). No Golfo do México (GoM), onde *seepage slicks* e *oil spills* podem ocorrer simultaneamente, distinguir a origem das manchas de óleo (OMO) usando SAR é desafiador. Modelos preditivos para identificação da OMO no GoM foram desenvolvidos utilizando 26 atributos geométricos, extraídos de 6.279 manchas de óleo validadas. Os modelos GoM treinados e testados com algoritmos de *Machine Learning* alcançaram precisão máxima de 75%. De forma inédita, estes modelos foram aplicados para prever amostras desconhecidas na Margem Continental Brasileira utilizando *Transfer Learning*. Os resultados demonstraram a capacidade de generalização dos modelos GoM atingindo 87% de precisão empregando satélites semelhantes. Predições automáticas agregam confiança à análise dos intérpretes, minimizando riscos geológicos para geração e migração de óleo em novas fronteiras exploratórias *offshore*.

Palavras-chave - Radar de Abertura Sintética, *Machine Learning*, *Transfer Learning*, Exsudação de Óleo, Derrame de Óleo.

ABSTRACT

Natural or anthropic oil slicks induce the sea surface roughness attenuation, being similarly detected as dark spots by Synthetic Aperture Radars (SAR). Thereby, in the Gulf of Mexico (GoM), where seepage slicks and oil spills can occur simultaneously, distinguishing the oil slick source (OSS) using SAR is challenging. A database with 26 geometric features, extracted for 6,279 validated oil slicks, was used to develop predictive models for OSS identification in the GoM. A Machine Learning processing chain was implemented to train and test the GoM models achieving maximum accuracy around 75%. These models were first-ever applied to predict unknown samples in the Brazilian Continental Margin employing Transfer Learning. Results demonstrated the generalization capacity of the GoM models, achieving 87 % of accuracy when using similar satellites. Automatic predictions add confidence to the interpreters' analysis,

minimizing inherent risks regarding oil generation and migration in new offshore exploratory frontiers.

Key words - *Synthetic Aperture Radar, Machine Learning, Transfer Learning, Seepage Slick, Oil Spill.*

1. INTRODUÇÃO

Nas indústrias de óleo e gás, a busca por novas fronteiras exploratórias em águas profundas e ultra-profundas é um empreendimento de alto risco. Embora levantamentos geofísicos disponibilizem dados estratégicos, os mesmos não são conclusivos sobre o fenômeno de geração e migração de petróleo [1]. Nesse contexto, a detecção de exsudações de óleo no ambiente marinho contribui para reduzir incertezas, pois fornece evidências indubitáveis da presença de sistemas petrolíferos ativos [1-3].

Nas imagens de Radar de Abertura Sintética (SAR), manchas de óleo de origem natural (*seepage slicks*) ou antrópica (*oil spills*) induzem o mesmo mecanismo físico de amortecimento da rugosidade da superfície do mar, sendo similarmente exibidas como manchas escuras em regiões de baixo retroespalhamento [2-7].

Algoritmos de *Machine Learning* (ML) têm sido utilizados para desenvolver sistemas inteligentes capazes de reconhecer distintamente esses padrões, generalizar o conhecimento apreendido e realizar inferências em novos conjuntos de dados [2,6,7]. A principal limitação do ML usual é a suposição de que os dados de treinamento, teste e validação apresentam propriedades estatísticas equivalentes, o que pode não se observar no mundo real [8,9]. Desse modo, métodos de *Transfer Learning* (TL) permitem extrair e armazenar conhecimento de modelos previamente treinados e transferi-lo para otimizar as acurácias de predição em feições estatisticamente não similares [8,9].

De forma inédita, modelos preditivos desenvolvidos no Golfo do México (GoM) foram aplicados para distinguir *seepage slicks* de *oil spills* em fronteiras exploratórias *offshore* da Margem Continental Brasileira (BR) empregando técnicas de TL. Para tal, foram avaliados o potencial discriminatório de 26 atributos geométricos e o uso de satélites diversos para detectar manchas de óleo em um contexto meteo-oceanográfico distinto do observado no GoM [10].

A TL pode agregar valor à tomada de decisão na aprovação de locações exploratórias sobre a presença de geração e migração de óleo. No caso das manchas naturais de óleo na superfície do mar, a possibilidade de se transferir conhecimento de bases robustas e controladas para feições em outras regiões geográficas pode antecipar resultados sem a necessidade de aquisição e validação de novas imagens SAR para re-treinar os modelos.

1.1. Fundamentos Teóricos: Transfer Learning

Para o desenvolvimento e aplicação de modelos preditivos utilizando TL, é essencial definir tarefa (T) e domínio (D). O domínio refere-se ao conjunto de amostras disponível para construir e validar modelos preditivos. O domínio fonte (D_F) compreende amostras validadas e balanceadas para treinar e testar modelos preditivos, enquanto o domínio alvo (D_A) é composto por novas amostras a serem preditas pelo modelo. A tarefa indica a finalidade das amostras utilizadas nos domínios fonte e alvo [8,9]. Nesta pesquisa, as tarefas T_F e T_A têm o mesmo objetivo de classificar as manchas de óleo atribuindo o rótulo (Y) 1 para a classe *seepage slick* e 0 para a classe *oil spill* ($Y \in \{0, 1\}$).

Existem três tipos de TL: indutiva, transdutiva e não supervisionada [8,9]. A aprendizagem por transferência transdutiva reproduz as propriedades do banco de dados utilizado, onde muitas amostras de manchas de óleo validadas e rotuladas estão disponíveis no domínio fonte D_F , enquanto nenhum dado rotulado é fornecido no domínio alvo D_A [8,9]. As diferenças entre os domínios fonte e alvo ($D_F \neq D_A$) podem ser referentes ao uso de: i. rótulos diversos (Y); ii. diferentes espaços de atributos (X); iii. atributos iguais (X) com distribuições de probabilidade marginal distintas ($P(X)$), também conhecidas como *pdf(s)* [8,9].

Como no presente estudo as tarefas ($T_F = T_A$), rótulos ($Y_F = Y_A$) e espaços de características ($X_F = X_A$) são equivalentes para ambos os domínios, D_F e D_A são diferentes apenas em termos de distribuições estatísticas ($P(X_F) \neq P(X_A)$), onde $X = \{x_1, \dots, x_n\} \in \mathcal{X}$ é um vetor contendo 26 atributos geométricos calculados para cada mancha de óleo. Nesse caso, há uma mudança ou desvio inerente na distribuição estatística dos atributos nos domínios D_F e D_A , o que requer ajustes para transferir o aprendizado de forma efetiva [9]. Técnicas de adaptação de domínio (AD) são utilizadas para minimizar diferenças entre os domínios D_F e D_A ($P(X_S) \neq P(X_T)$) [8,9,11], transferindo conhecimento e, conseqüentemente, melhorando o desempenho de previsão dos modelos [11].

2. BASE DE DADOS E METODOLOGIA

Uma base de dados robusta, balanceada e validada em campo pela PEMEX (*Petróleos Mexicanos*), com 6.279 manchas de óleo detectadas no GoM com os satélites RADARSAT-1 (RDS1) e RADARSAT-2 (RDS2), foi usada para desenvolver modelos preditivos com diferentes algoritmos de ML [10].

As imagens SAR foram pré-processadas e interpretadas por especialistas em sensoriamento remoto para mapear a presença de manchas de óleo. Nessa tarefa, o Classificador

Textural por Semivariograma não Supervisionado (USTC) foi utilizado em conjunto com a Análise Iterativa de Auto-Organização de Dados (ISODATA) para extrair os polígonos das manchas de óleo [12]. O espaço de atributos (X) é composto por um atributo categórico (Y) associando a cada mancha o rótulo 1 para *seepage slicks* e 0 para *oil spills*, além de 26 atributos geométricos calculados a partir de cada polígono.

A metodologia abrange o desenvolvimento de modelos preditivos no GoM (D_F) e sua respectiva aplicação para prever a origem das manchas de óleo detectadas na BR (D_A). As amostras disponíveis por classe nos domínios D_F e D_A estão indicadas na Figura 1.

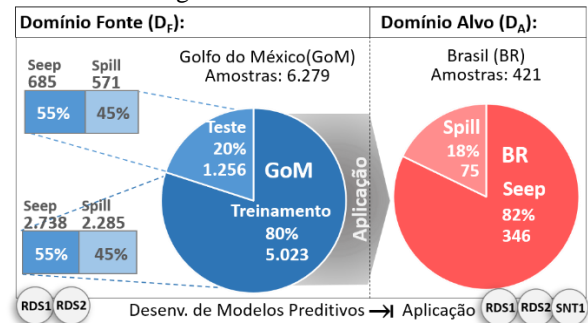


Figura 1. Feições de óleo disponíveis para o desenvolvimento dos modelos (D_F) e aplicação (D_A) em amostras desconhecidas.

A primeira etapa é dedicada à construção dos modelos GoM (D_F) e abrange: i. pré-processamento, incluindo a normalização dos dados; ii. análise exploratória; iii. seleção de atributos; iv. treinamento e teste dos modelos testando: *Artificial Neural Networks* (ANN), *Random Forest* (RF), *Gaussian Naive Bayes* (GNB), *Linear Discriminant Analysis* (LDA), *Support Vector Machine* (SVM), *Logistic Regression* (LR) e *K Nearest Neighbor* (KNN); v. seleção dos melhores modelos para serem aplicados na predição de novas amostras.

Na segunda etapa, a generalização dos modelos GoM foi avaliada através de sua aplicação em 421 novas feições de óleo identificadas em dados SAR da BR, adquiridas em condições meteo-oceanográficas distintas, com os satélites RDS1 e RDS2, incluindo o SENTINEL-1 (SNT1), não considerado no treinamento dos modelos. Na aplicação GoM \rightarrow BR os melhores modelos GoM (D_F) foram salvos e aplicados sobre amostras desconhecidas na BR para prever sua origem como *seepage slick* ou *oil spill*. Dois métodos de AD, o *Common Data Shift* (CDS) e o *Data Interpolation* (DI), foram testados para transferir conhecimento e minimizar diferenças entre os domínios D_F e D_A .

O CDS é aplicado sobre um conjunto de amostras, incorporando a distribuição da origem ($P(X_F)$) no destino ($P(X_A)$) [9,11] e integrando desta forma o domínio D_F com o D_A através da normalização conjunta. Já a o DI é aplicado amostra por amostra, empregando a frequência acumulada (FA) salva para cada atributo no D_F para mapear um valor correspondente para a amostra desconhecida no D_A , tendo como base sua respectiva frequência acumulada normalizada (FAN).

Tanto a FA quanto a FAN são salvas para cada atributo selecionado na construção do modelo (D_F), consolidando um dicionário de padrões geométricos de manchas de óleo no GoM. Cada nova amostra no D_A é interpolada às curvas e associada a um valor normalizado equivalente.

Para fins científicos, as feições desconhecidas no domínio D_A são consideradas não rotuladas na aplicação. Sua origem, interpretada com base no conhecimento dos especialistas, foi usada somente após o término das aplicações para avaliar o desempenho e a generalização dos modelos preditivos na BR, comparando o ML usual com os métodos de TL (CDS e DI).

3. RESULTADOS: DESENVOLVIMENTO E APLICAÇÃO DE MODELOS PREDITIVOS

O modelo preditivo desenvolvido no GoM alcançou uma acurácia global (AGI) máxima de teste de 75,24% no reconhecimento de *seepage slicks* e *oil spills* (Tabela 1a). Os primeiros 5 algoritmos testados retornaram os melhores desempenhos (SVM, RF, ANN, LDA, LR). Para estes, as métricas de AGI e F-Score variaram entre 74% (LR) e 75% (SVM).

A distância entre as acurácias mínima e máxima, calculada para os Intervalos de Acurácia (IA) referentes a cada algoritmo utilizando validação cruzada, mostrou que não há indícios de *overfitting* nos modelos GoM (Tabela 1b).

Os desvios padrões dos IA acima de 2, bem como as maiores áreas sob as curvas ROC (AUC(s)), confirmam os 5 primeiros algoritmos de ML como os de melhor desempenho para identificar *seepage slicks* (Tabela 1b). Estes 5 melhores modelos GoM foram salvos e aplicados para inferir as feições de óleo desconhecidas detectadas na BR.

GoM: Algoritmos de ML	(a) Acurácias de Teste: Matriz de Confusão		(b) Validação Cruzada: K-Fold = 5		
	Acurácia Global	F-Score	Intervalo de Acurácia (IA)	IA Desv. Pad.	AUC
SVM	75,24	75,21	71,75% ~ 77,25%	1,37	81,53
RF	74,68	74,61	71,95% ~ 78,64%	1,67	80,94
ANN	74,20	74,16	65,72% ~ 77,93%	3,05	81,43
LDA	73,89	73,78	70,10% ~ 78,11%	2,00	80,49
LR	73,89	73,80	66,28% ~ 77,94%	2,92	80,77
KNN	73,09	73,08	70,41% ~ 75,40%	1,25	77,93
GNB	72,69	72,75	70,88% ~ 74,94%	1,02	79,69

Tabela 1. Acurácias de teste para o modelo GoM.

A transferência de conhecimento dos modelos GoM para inferir feições no Brasil foi efetiva (Tabela 2, Figura 2), indicando AGI máximas de predição maiores com o emprego de TL (CDS: 65,08%; DI: 66,51%) do que com ML usual (58,91%). Comportamento similar é observado para a métrica de F-Score, que alcançou AGI máxima de 78,67% na identificação de *seepage slicks* com DI.

Modelos Preditivos Aplicados	Modelo GoM aplicado no BR com todos os Satélites					
	(a) Machine Learning Usual		(b) TL: Common Data Shift		(c) TL: Data Interpolation	
	AGI	F-Score	AGI	F-Score	AGI	F-Score
LR	56,06	68,05	65,08	77,56	66,51	78,67
LDA	57,48	69,51	64,85	77,37	66,03	78,30
ANN	54,63	67,24	64,37	76,85	64,61	77,04
SVM	58,91	71,78	63,42	76,23	63,90	76,62
RF	55,82	68,58	64,61	76,90	63,66	76,35

Tabela 2. Métricas de acurácia para diferentes métodos de aplicação: (a) ML usual; (b) TL: CDS; (c) TL: DI.

A DI retornou melhores desempenhos, provavelmente porque, ao prever uma amostra por vez, tal método adapta o D_A ao D_F preservando as propriedades geométricas originais extraídas das manchas de óleo. Já a normalização conjunta realizada pelo CDS adapta as distribuições fonte e alvo simultaneamente, alterando a(s) *pdf(s)* no domínio fonte ($P(X_F)$).

As transferências positivas evidenciaram que foi possível generalizar os modelos GoM para fazer inferências no Brasil com TL (Figura 2: linhas azuis), ultrapassando as performances obtidas com ML (Figura 2: linha vermelha). Todavia, estima-se que as feições de óleo detectadas na BR por um conjunto de satélites diferente (RDS1, RDS2, SNT1) do utilizado para treinar o modelo GoM (RDS1, RDS2) geraram distribuições altamente divergentes, prejudicando a transferência de conhecimento entre os domínios D_F e D_A .

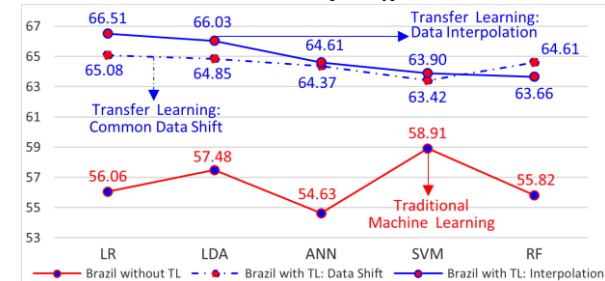


Figura 2. GoM → BR: AGI para os 5 melhores algoritmos de ML, considerando domínios diferentes ($D_F \neq D_A$) e estratégias de aprendizado distintas: ML, CDS e DI.

Para verificar essa hipótese, uma análise adicional (Tabela 3 e Figura 3) foi realizada empregando DI e feições de óleo detectadas com os mesmos satélites (RDS) empregados no treinamento dos modelos GoM. Tal procedimento evidenciou uma transferência positiva surpreendente (Figura 3: linhas azuis com marcadores verdes) com acurácias de até 87% (Tabela 3c). Inversamente, a DI aplicada em amostras detectadas com o SNT1 (Tabela 3d) provocou transferências negativas (Figura 3: linhas vermelhas), degradando (AGI: 34,76%) ao invés de melhorar as AGI(s) em relação ao ML usual (Tabela 3a AGI: 58,91%). Comportamento similar é observado para as métricas de F-Score.

GoM: Modelos Preditivos Aplicados	ML Usual		Transfer Learning: Data Interpolation			
	(a) Σ Satélites	(b) Σ Satélites	(c) RADARSAT	(d) SENTINEL	(b) Σ Satélites	(c) RADARSAT
	AGI	F-Score	AGI	F-Score	AGI	F-Score
LR	56,06	68,05	66,51	78,67	87,16	93,14
LDA	57,48	69,51	66,03	78,30	86,77	92,92
ANN	54,63	67,24	64,61	77,04	83,66	91,10
SVM	58,91	71,78	63,90	76,62	84,82	91,79
RF	55,82	68,58	63,66	76,35	82,49	90,41

Tabela 3. AGI e F-Score para as amostras preditas na BR utilizando ML e DI: (a) todos os satélites; (b) RDS; (c) SNT1.

Provavelmente, as configurações específicas de cada sistema SAR influenciaram diretamente as propriedades geométricas das manchas de óleo extraídas das imagens. A diferença entre as resoluções espaciais dos dados dos satélites RDS

(50m) e SNT1 (10m redimensionado para 20m) gerou amostras com distribuições estatísticas altamente divergentes em relação ao D_F . Tal efeito provocou transferências negativas (Figura 3: linhas vermelhas) para o D_A , reduzindo até 27,81% da AGI (no caso do SVM) em relação ao ML usual com todos os satélites (Figura 3: linha preta).

Os resultados mostram que as amostras detectadas com SNT1 na BR influenciaram negativamente as acurácias de predição. De fato, a AGI somando todos os satélites não ultrapassou 66,51% (Tabela 3b, Figura 3: linhas azuis com marcadores azuis). Entretanto, após a exclusão das amostras SNT1, a TL foi significativamente positiva, retornando até 87,16% de *seepage slicks* corretamente classificados (em relação ao conhecimento do especialista) pelo modelo GoM utilizando DI e LR (Tabela 3c).

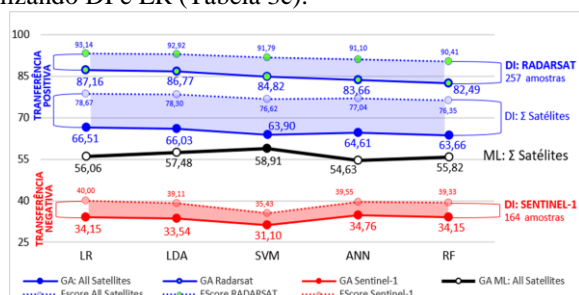


Figura 3. Performances de predição utilizando DI considerando todos os satélites e as missões RDS e SNT1 isoladamente.

Portanto, a aplicação GoM→BR provou que, ao se empregar sensores SAR semelhantes aos utilizados no treinamento dos modelos, é possível transferir conhecimento para uma região geográfica distinta, influenciada por diferentes condições meteo-oceanográficas e prever manchas desconhecidas com excelentes *performances* em relação ao conhecimento do especialista.

4. CONCLUSÕES

A adaptabilidade, transferibilidade e capacidade de generalização dos modelos GoM ao lidar com diferentes domínios ($D_F \neq D_A$) foi comprovada na aplicação GoM→BR. Ao prever amostras detectadas com satélites similares aos utilizados no treinamento dos modelos GoM, foi possível alcançar AGI de até 87,16%. Nesse caso, é possível migrar a aplicação GoM→BR para um ambiente operacional e prever feições de óleo desconhecidas detectadas na BR sem a necessidade de adquirir novas amostras e re-treinar os modelos. Entretanto, ao empregar um satélite diferente (SNT1) dos utilizados no treinamento dos modelos, as acurácias pioraram (34,76%) em relação ao ML usual (58,91%). Nesse caso, para uso operacional em escala de bacia sedimentar, é necessário adquirir novas amostras com o satélite SNT1 e re-treinar os modelos GoM do zero.

Como a cada novo ciclo de treinamento e teste os modelos melhoram o reconhecimento de antigos e novos padrões, minimizando as incertezas de predição, é essencial investir no incremento contínuo da base de dados GoM com novas amostras

validadas em campo, incluindo aquisições com o SNT1.

Investimentos na ampliação dessas bases de dados podem oferecer impactos econômicos significativos para a indústria de petróleo e gás, considerando que modelos robustos e bem treinados para detectar *seepage slicks* em uma determinada região sedimentar podem ser aplicados em outras bacias, ampliando a área de busca por novas fronteiras exploratórias. Portanto, quanto maior o número e a diversidade de *seepage slicks* validados no domínio D_F , menor será a necessidade de investir tempo, recursos humanos e financeiros na aquisição de amostras em novas áreas de interesse para re-treinar ou construir novos modelos preditivos.

Em novas fronteiras exploratórias *offshore*, modelos automáticos capazes de inferir a origem natural ou antrópica das manchas de óleo são estratégicos por agregar confiança à análise dos intérpretes, reduzindo consequentemente o risco geológico referente aos fenômenos de geração e migração.

5. REFERÊNCIAS

- [1] Dembicki Jr. Harry. (2020) Reducing the risk of finding a working petroleum system using SAR imaging, sea surface slick sampling, and geophysical seafloor characterization. *Marine and Petroleum Geology* 115, 104276.
- [2] Matias, I.O.; Genovez, P.C.; & colabs. (2021) Improved Classification Models to Distinguish Natural from Anthropic Oil Slicks in the Gulf of Mexico: Seasonality and Radarsat-2 Beam Mode Effects under a Machine Learning Approach. *Remote Sens.*, 13, 4568.
- [3] Macdonald, I. R.; Garcia-Pineda O.; & colabs. (2015) Natural and unnatural oil slicks in the Gulf of Mexico. *Journal of Geophysical Research: Oceans*, 120(12),
- [4] Brekke, C. & Solberg, A. H. S. (2005) Oil spill detection by satellite remote sensing. *Remote Sensing of Environment*, 95(1), 1–13.
- [5] Alpers, W.; Holt, B.; Zeng, K. (2017) Oil spill detection by imaging radars: Challenges and pitfalls. *Remote Sensing of Environment*, 201(C), 133–147.
- [6] Al-Ruzouq, R.; Gibril, M.B.A.; & colabs. (2020) Sensors, Features, and Machine Learning for Oil Spill Detection and Monitoring: A Review. *Remote Sens.*, 12, 3338.
- [7] Genovez, P. C.; Ebecken, N.F.F. & colabs. (2017) Intelligent hybrid system for dark spot detection using SAR data. *Expert Systems with Applications*, 81(NA), 384–397.
- [8] Pan, S. J. & Yang, Q. (2009) A Survey on Transfer Learning. *IEEE Transactions on Knowledge and Data Engineering*, 22(10), 1345–1359.
- [9] Kouw, W. M. & Loog, M. (2019) Technical report: An introduction to domain adaptation and transfer learning. Cornell University, 1-41.
- [10] Miranda, F.P.; Silva, G.M.A.; & colabs. (2022) Geometric Pattern Recognition Using Machine Learning: Predictive Models to Distinguish Natural from Anthropic Oil Slicks in the Gulf of Mexico. Conference: Proceedings of Rio Oil & Gas 2022.
- [11] Quinonero-Candela, J.; Sugiyama, M.; & colabs. (2009) *Dataset Shift in Machine Learning*. Massachusetts Inst. of Technology Press.
- [12] Miranda, F.P.; Marmol A.M.Q.; & colabs. (2004) Analysis of RADARSAT-1 data for offshore monitoring activities in the Cantarell Complex, Gulf of Mexico, using the unsupervised semivariogram textural classifier (USTC). *Canadian Journal of Remote Sensing*, 30(3), 424.