

UNIVERSIDADE ESTADUAL PAULISTA
PROGRAMA DE PÓS-GRADUAÇÃO EM GEOCIÊNCIAS E MEIO AMBIENTE
IGCE – INSTITUTO DE GEOCIÊNCIAS E CIÊNCIAS EXATAS

Relatório de Pós-doutorado

**ANÁLISE DA APLICABILIDADE DE MÉTODOS DE CLASSIFICAÇÃO
MACHINE LEARNING E DEEP LEARNING NO MAPEAMENTO DE ÍNDICE
SENSIBILIDADE AMBIENTAL**

PÓS-DOCTORANDO: Mara Lucia Marques

SUPERVISOR: Prof. Dr. Fábio Augusto Gomes Vieira Reis

Rio Claro
2025

Resumo

Dentre as técnicas e métodos de sensoriamento remoto, destaca-se a classificação automática (supervisionada ou não supervisionada), empregadas em diversos estudos, como mapeamento de uso e ocupação do solo, detecção de mudanças de cobertura do solo. Assim, o objetivo foi contribuir para realização de Cartas SAO em ambientes litorâneos, a partir de métodos de reconhecimento automatizados de padrões, com vistas a efetividade na classificação cobertura do solo, detecção de feições e delimitação de linha de costa em diferentes escalas cartográficas. Foi realizado o levantamento de produtos cartográficos e produtos de sensoriamento remoto, a fim de constituir o Banco de Dados Geográfico empregado para aplicação dos métodos de classificação automática. Para a classificação, foram empregados os algoritmos: a) Support Vector Machine (SVM), que empregou algoritmos de otimização para localizar os limites ótimos entre as classes; b) Random Forest (RF) que consiste em um classificador supervisionado por aprendizado de máquina que gera uma infinidade de árvores de decisão; e c) Convolutional neural networks (CNN), que usa várias camadas de algoritmos na forma de redes neurais. Os resultados possibilitaram: (i) estruturar um banco de dados geográfico com integralidade e interoperabilidade; (ii) analisar a acurácia dos métodos de detecção automática na delimitação de feições ambientais; e (iii) averiguar a aplicabilidade da classificação automática da cobertura do solo na análise da sensibilidade ambiental. A comparação dos métodos de classificação empregados, demonstrou que os modelos RF e SVM apresentam maior acurácia que o CNN empregado. As vantagens observadas foram, respectivamente, bom desempenho com dados espectrais distintos, robustez e tolerância a sobreajuste e extração de padrões complexos espaciais. Os resultados observados estão alinhados com o fato que o RF é eficiente e de rápida implementação em projetos com menor disponibilidade computacional, e que o SVM é eficaz quando aplicado em amostras de treino selecionadas com precisão.

Palavras chaves: Sensoriamento Remoto, Modelos de Classificação, Sensibilidade Ambiental.

1. Introdução

O petróleo representa elemento fundamental no subsistema antrópico. Atualmente, é fonte não só de energia, mas também de matéria prima de diferentes produtos e se tornou indispensável na movimentação dos diversos fluxos de matéria, energia e informação, os quais exercem grande importância no sustento das atividades dos subsistemas sociais e econômicos modernos (ARAÚJO et al., 2002).

Desde o local de prospecção do petróleo até seu refino e distribuição aos centros consumidores de seus derivados, faz-se necessária uma rede logística destinada ao transporte dos diversos componentes. Esta rede produtiva está inserida em todos os modais de transporte (marítimo, rodovias, ferrovias, hidrovias e dutovias), envolvendo navios petroleiros, oleodutos, vagões tanque no transporte ferroviário, caminhões, que expõem o meio ambiente a uma variedade de cenários acidentais envolvendo uma grande variedade de produtos (petróleo e derivados) podendo resultar em significativos impactos ao meio ambiente e às atividades socioeconômicas (NELSON e GRUBESIC, 2018; ARAÚJO et al., 2002).

Com aumento dessas atividades ocasionam vários acidentes de grande repercussão na mídia pela magnitude das suas consequências. Dentre eles, merece destaque o acidente com o navio Exxon Valdez na baía de Prince William, no Alasca, em 1989, o qual, por ter ocorrido em área abrigada com elevados recursos biológicos e importantes atividades socioeconômicas, ficou marcado como um dos piores eventos ambientais do mundo contemporâneo. O desastre levou os órgãos responsáveis à regulamentação das atividades da indústria do petróleo no mundo a estabelecerem uma legislação internacional que, no âmbito ambiental, traçou diretrizes quanto às atividades de prospecção, transporte e armazenamento de petróleo e derivados (ARAÚJO et al., 2006).

A Convenção Internacional sobre Preparo, Responsabilidade e Cooperação em caso de Poluição por Óleo (OPRC 90) foi a principal convenção relacionada a derramamento de petróleo e norteou todas as atividades dos países signatários quanto aos procedimentos de prevenção e combate a derramamento de óleo, incluindo os Planos de Contingência e as Cartas de Sensibilidade Ambiental (WIECZOREK, 2006) e ocorreu impulsionada pelo acidente do Exxon Valdez. Em 1995, o Brasil passou a ser um de seus signatários. Um dos principais aspectos estabelecidos pela convenção é que os países deverão estabelecer planos nacionais de contingência, a partir de planos de emergência individuais para terminais, portos e plataformas (ARAÚJO et al., 2002).

No Brasil, a Lei Federal 9.966, de 22 de Abril de 2000, regulamentou as ações ligadas ao transporte e armazenamento de óleo. Esta lei define que o órgão federal do meio ambiente, em consonância com o disposto na OPRC 90, consolidará os planos de contingências locais e regionais, na forma do Plano Nacional de Contingência. Os planos de contingência estabelecem as diretrizes de ações de resposta aos derrames de óleo de um terminal, porto, cidade, estado ou país, dependendo da escala do evento (IPIECA, 2000).

As ações destinadas a minimizar os impactos de um derrame de óleo incluem a definição dos responsáveis pelas ações, os recursos disponíveis para o combate a acidentes e o estabelecimento de áreas prioritárias para a proteção (O'BRIEN-DELPESH, et al., 2022). Um dos principais objetivos do planejamento de resposta é reduzir, tanto quanto possível, as consequências ambientais de um acidente. Esse objetivo é alcançado quando os locais mais sensíveis, as áreas prioritárias de proteção e os métodos de limpeza para cada área estão pré-definidos. Nesse contexto, inserem-se as cartas de sensibilidade derrames de óleo, Cartas SAO (JENSEN et al., 1998). As Cartas SAO constituem-se em documentos cartográficos que servem como ferramenta crítica no planejamento e nas respostas a acidentes envolvendo o derramamento de óleo.

Na elaboração das Cartas SAO e determinação dos índices de sensibilidade ambiental os métodos de fotointerpretação e classificação visual de imagens são empregados para identificação de feições geomorfológicas e de uso e cobertura do solo (CASTANEDO et al., 2009). O emprego métodos de classificação automática supervisionadas, principalmente utilizando técnicas de treinamento de máquina por aprendizado profundo (Machine Learning), visam contribuir na otimização do processo de mapeamento dos índices ambientais, como também na atualização das análises (BYCROFT et al., 2019; RODRIGUEZ-GALIANO et al., 2012).

O aprendizado de máquina supervisionado consiste na tarefa de programar a máquina para aprender uma função que mapeia uma entrada para uma saída, com base em pares de entrada-saída de exemplo, ou seja, será inferida uma função, a partir de conjunto de dados de treinamento rotulados, gerando um conjunto de dados de entrada que é dividido em conjunto de dados de treinamento e de teste de avaliação (MAHESH, 2018; BYCROFT et al., 2019). Destaca-se que o conjunto de dados do treinamento tem uma variável de saída que precisa ser prevista ou classificada. Os algoritmos aprendem os tipos de padrão

do conjunto de dados de treinamento e os aplicam ao conjunto de dados para gerar predições ou classificações (MAHESH, 2018).

Assim, a investigação da aplicabilidade dos métodos de classificação supervisionada por aprendizado profundo no processo de mapeamento do índice de sensibilidade ambiental, na classificação da cobertura do solo (LULC) e detecção de feições (BYCROFT et al., 2019; RODRIGUEZ-GALIANO et al., 2012) poderiam aprimorar a metodologia de elaboração de Carta SAO, devido à natureza dinâmica dados abordados, como as atividades antropogênicas e processos naturais, ou seja, processos e estruturas de uso e ocupação do solo, mudanças no nível do mar, sedimentação e litorais de energia das ondas, delimitação de linha de costa em diferentes escalas cartográficas.

A metodologia utilizada para a elaboração das cartas SAO em uso no Brasil é uma adaptação (MMA, 2002) daquela desenvolvida pela National Oceanic and Atmospheric Administration, NOAA, dos Estados Unidos (NOAA, 1995). Praticamente todos os países do mundo aplicam tal metodologia, com pequenas adequações. Ela estabelece um padrão de nomenclatura e os índices de sensibilidade ambiental ao óleo. Assim, são levantados e mapeados os parâmetros físicos e químicos (ou dados abióticos, muitas vezes designados de dados geomorfológicos), os recursos biológicos, os aspectos socioeconômicos e os índices de sensibilidade ambiental ao óleo da área de interesse; todos esses elementos integram as cartas finais. Normalmente os dados sócioeconômicos que são agregados às cartas SAO têm caráter meramente descritivo, sendo insuficientes para um processo mais analítico; isto impossibilita, por exemplo, o estabelecimento de indicadores socioeconômicos consistentes (D'AFFONSECA et al., 2023)

O sensoriamento remoto pode ser utilizado como importante conjunto de técnicas de pesquisa para monitorar as diferentes formas de ocupação do espaço e caracterizar suas tendências de expansão, bem como os problemas ambientais a ele relacionados, apresentando a vantagem de obtenção de dados em menor tempo e custo, quando comparado às técnicas baseadas apenas por levantamentos de campo (COSTA, 1996).

Dentre as técnicas e métodos de sensoriamento remoto, destaca-se a classificação automática (supervisionada ou não supervisionada), empregadas em diversos estudos, como mapeamento de uso e ocupação do solo, detecção de mudanças de cobertura do solo, entre outros (LIU et al., 2008). No monitoramento e análise da sensibilidade ambiental, a classificação automática é um método de interpretação que permite

maximizar a extração de informações sobre um determinado fenômeno, permitindo modelar a situação atual ou prever a transformações no tempo (BYCROFT et al., 2019).

Na classificação do uso e cobertura do solo, um importante fundamento no processo de classificação de imagens é definição a das categorias de cobertura do solo ou a detecção dos objetos requerem a elaboração de estrutura hierárquica fundamentada na semântica e nas características físicas das feições ou entidades de cobertura da superfície analisada, na qual a abordagem semântica representa uma estrutura lógica que relaciona os objetos ou classes a partir dos seus significados e relações (ANTUNES, 2003; RODRIGUEZ-GALIANO et al., 2012).

De acordo, com Schiller et al. (2005) a classificação por aprendizado profundo objetiva reproduzir decisões de especialistas humanos sobre a classificação de classes de sensibilidade ambiental, aplicando algoritmos como às Autoassociative Neural Network (AANN) na classificação automatizada da biota na região costeira, complementando o índice de sensibilidade ambiental de forma a alcançar uma melhor diferenciação espacial da diversidade de habitats. Outro método que resulta em probabilidades robustas e precisas na diferenciação de categorias de dados é o método Random Forest (RF) que pode atingir elevada precisão estatística na classificação de conjuntos de dados complexos e ocorrência de variáveis aleatórias (RODRIGUEZ-GALIANO et al., 2012; HAMID et al., 2023). A classificação pelo método RF também apresenta como vantagem empregar grandes bancos de dados, considerar diferentes variáveis de entrada, como os dados socioeconômicos.

2. Objetivo

O objetivo da pesquisa foi contribuir na elaboração de metodologia para realização de Cartas SAO em ambientes litorâneos, analisando a aplicabilidade de métodos de reconhecimento automatizados de padrões (machine learning e deep learning) como procedimentos complementares do processo de mapeamento de Índice Sensibilidade Ambiental (ISA), com vistas a efetividade na classificação cobertura do solo (LULC), detecção de feições e delimitação de linha de costa em diferentes escalas cartográficas.

3. Material e Método

3.1 Elaboração do banco de dados geográfico do projeto

Nesta etapa foi realizado o levantamento de produtos cartográficos e produtos de sensoriamento remoto, a fim de constituir a base de dados espacial em sistema de informação geográfica empregado para aplicação dos métodos de classificação automática. Como a área de estudo foi definida a baía Santos/Cubatão, situada no litoral do estado de São Paulo. A baía de Santos está situada na unidade fisiográfica da Baixada Santista na porção central do litoral paulista, sendo um ambiente marinho delimitado externamente pelas pontas de Itaipú, em Praia Grande, a oeste; pela Ponta do Monduba, no Guarujá, a leste; e pela ilha de São Vicente, a norte. Esse compartimento recebe as contribuições dos canais de Santos e de São Vicente, e da baía de São Vicente, constituindo-se numa zona de mistura da água do mar com as águas salobras provenientes dos estuários. Esse estuário apresenta profundidade média entre 5 a 10 metros; com cerca de 7km de largura na parte central e 11km em sua entrada (SUGUIO, 1992; LAMPARELLI et al., 2001; ROCHA, 2009).

A região de entorno da baía de Santos possui importância socioeconômica devido a vocação portuária e também turística, como também, pólo industrial e petroquímico. Dessa forma, essas atividades acarretam intensa movimentação de embarcações pela baía de Santos constituindo importantes fontes potenciais de poluição por óleo, seja nas operações de abastecimento, nas de limpeza e descarte de óleo residual, ou ainda em eventuais acidentes de navegação (POFFO, 2007; VENANCIO, 2018).

O Banco de Dados Geográfico utilizou o modelo teórico semântico para abordar as informações da realidade, considerando o modelo conceitual para a implementação gráfica dos fenômenos ambientais, e traduzindo a realidade como representação geométrica e atributos alfanuméricos para inserir os dados em meio digital (GOODCHILD, 1992). O BDG foi projetado seguindo uma arquitetura de sistema multicamadas, na qual a organização é referida como um modelo de banco de dados relacionado a objetos (ESRI, 2023).

3.2 Processamento dos produtos de sensoriamento remoto

Processamentos digitais de imagem, como ampliação de contraste, filtragem espacial, fusão de bandas e componentes principais serão aplicados para realçar as feições

de interesse (LILLESAND e KIEFER, 2000; MENESES e ALMEIDA, 2012) e auxiliar na sua identificação.

3.3 Classificação automática de imagens

O processo de extração de entidade orientada a objetos foi realizado por três principais ferramentas: segmentação de imagens, derivação de informações analíticas sobre segmentos e classificação. Esse processo pode empregar técnicas de classificação supervisionadas e não supervisionadas na identificação de classes dos segmentos, para obtenção da imagem classificada. A segmentação da imagem foi baseada na abordagem de deslocamento médio, que emprega a técnica de janela móvel que calcula um valor médio de pixel para determinar os pixels a serem incluídos em cada segmento, utilizando os parâmetros: detalhe espectral (20), detalhe espacial (5) e tamanho mínimo do segmento (2). Assim, à medida que a janela se move pela imagem, ela recalcula iterativamente o valor para garantir que cada segmento seja apropriado (COMANICU e MEER, 2002).

Para o treinamento de aprendizagem supervisionada foram coletadas amostras de referência que representam entidades específicas e que são delineados, a partir da imagem (Figura 1). No treinamento de aprendizado profundo os dados vetoriais ou dados raster marcados em conjuntos de dados de treinamento sobre as imagens de sensoriamento remoto, obtendo os arquivos de imagem e de metadados.




Figura 1 – Treinamento de aprendizagem supervisionada. Fonte: Adaptado de Mahesh (2018).

Como algoritmos de classificação, foram empregados os métodos de classificação:

- a) *Support Vector Machine – SVM*, que empregou algoritmos de otimização para localizar os limites ótimos entre as classes, estatisticamente, os limites ótimos devem ser generalizados para amostras invisíveis com o mínimo de erros entre

todos os limites possíveis que separam as classes, minimizando assim a confusão entre as classes (HUANG et al., 2002). De acordo com os autores, o princípio indutivo do SVM é a minimização do risco estrutural. O risco é limitado pela soma do risco empírico estimado a partir de amostras de treinamento, em um intervalo de confiança, assumindo como estratégia a fixação do risco empírico e minimizar o intervalo de confiança, ou maximizar a margem entre um hiperplano de separação e os pontos de dados mais próximos. Um hiperplano de separação refere-se a um plano em um espaço multidimensional que separa as amostras de dados de duas classes. Além de executar a classificação linear, os SVMs podem executar com eficiência uma classificação não linear, empregando uma função kernel, e assim delimitam margens entre as classes, essas margens são definidas de forma que a distância entre a margem e as classes seja máxima e, portanto, minimizando o erro de classificação (MAHESH, 2018).

- b) *Random Trees* ou *Random Forest* que consiste em um classificador supervisionado por aprendizado de máquina que gera uma infinidade de árvores de decisão, escolhendo subconjuntos aleatórios de variáveis para cada árvore e usando a saída da árvore mais frequente como a classificação geral. Classificou o conjunto de dados uma série de vezes com base em uma sub-seleção aleatória de pixels de treinamento, resultando em inúmeras árvores de decisão. Para tomar uma decisão final, cada árvore recebe um voto. Esse método de classificação corrige a tendência das árvores de decisão de reajustadas em seus dados de amostra de treinamento (MAHESH, 2018; HAMID et al., 2023).
- c) Convolutional neural networks – CNN, o aprendizado de máquina que usa várias camadas de algoritmos na forma de redes neurais, assim os dados de entrada são analisados por meio de diferentes camadas da rede, com cada camada definindo recursos e padrões específicos nos dados. Foi empregado para a análise de imagem na identificação automaticamente de diversas feições geográficas, como corpos d'água, vegetação e área construída.

4. Resultados

O estudo produziu a estruturação de banco de dados geográfico com vistas às análises de sensibilidade ambiental, como por exemplo a associação entre as características da forma da linha costa e a sensibilidade ambiental, bem como a sensibilidade pode ser afetada pelos variações de uso e cobertura do solo em áreas costeiras. A partir dessas temáticas, os resultados possibilitaram: (i) estruturar um banco de dados geográfico com integralidade e interoperabilidade; (ii) analisar a acurácia dos métodos de detecção automática na delimitação de feições ambientais; e (iii) averiguar a aplicabilidade da classificação automática da cobertura do solo na análise da sensibilidade ambiental.

A partir da estruturação do banco de dados, foram especializados diferentes tipos de informações e a distribuição espacial dos dados relevantes para a caracterização e análise ambiental (Figura 2):

- A camada socioeconômica e ambiental, que foi composta por oito categorias: (1) Ocupação Urbana, que está diretamente relacionada à vulnerabilidade social local, como potenciais danos ou depreciação das áreas urbanas e do comércio local (comércio, equipamentos urbanos como hospitais, postos de saúde, escolas, bombeiros e delegacias de polícia, órgãos públicos, entre outros); (2) Recreação, que está relacionada a danos potenciais que levam ao fechamento de praias, contaminação de corpos d'água e possíveis intoxicações humanas (praias, residências de veraneio, hotéis, setores náuticos); (3) Cultural (por exemplo, locais de interesse histórico, templos religiosos); (4) A classe Áreas sob Manejo Especial, que apresenta atividades relevantes para ações de resposta a acidentes petrolíferos, localizadas em pontos estratégicos da costa (bases militares, órgãos de conservação ambiental e instituições de pesquisa); (6) Uso/Extração de Recursos Naturais, que representa as indústrias de derivados de hidrocarbonetos, usinas de geração de energia e mineração (pesca artesanal, recreativa e industrial, aquicultura, coleta de água); (7) Estruturas de Resposta, como zonas operacionais da Petrobras, terminais de petróleo e refinarias; e (8) Transporte, que desempenha um papel estratégico como rede de conexão entre locais críticos e recursos e instalações de contingência (modais de transporte terrestre, aquático e aéreo).
- As camadas relacionadas ao meio biótico, que apresentam os recursos bióticos, como resultado do levantamento da ocorrência de grupos e espécies, pertencentes aos grupos de aves, grupo de mamíferos, grupo de peixes, grupo de répteis anfíbios, grupo de

invertebrados marinhos, grupo de algas e plantas aquáticas, grupo plâncton, ictioplâncton, zooplâncton, fitoplâncton, outros grupos bentônicos e multigrupos.

- O Índice de Sensibilidade Ambiental (ESI) e as camadas de características relacionadas com ESI, que consistem numa análise da sensibilidade ambiental da linha de costa, permitindo a avaliação dos riscos e impactos dos derrames de petróleo. Este índice classifica os vários ambientes em uma escala crescente de sensibilidade, de 1 a 10, considerando fatores como exposição à energia das ondas e das marés, declividade costeira, tipo de substrato e biota associada.

- As camadas de base cartográficas e temáticas foram compostas por dados que incluíram limites territoriais (continente, país, estados e municípios, área continental), hidrografia (rede hidrográfica, corpo hídrico), redes rodoviárias, ferroviárias e dutoviárias, áreas construídas (industrial, portuária e urbana).

- As camadas de topografia e batimetria para representação do relevo, bem como camadas para caracterizar a bacia de Santos incluindo dados como geoquímicos, deriva das ondas e do mar e meteorológicos.




Figura 2 – Representação de dados espaciais em BDG.

A comparação dos métodos de classificação empregados, apresentados na Figura 3, demonstrou que os modelos RF e SVM apresentam maior acurácia que o CNN empregado. As vantagens observadas foram, respectivamente, bom desempenho com dados espectrais distintos, robustez e tolerância a sobreajuste e extração de padrões complexos espaciais. Enquanto que as principais limitações foram necessidade de ajuste fino para agrupamentos das classes, sensibilidade paridade da amostragem de treinamento e necessita de grande volume de dados e poder computacional



Algoritmo	Acurácia (%)	Mapa temático produto	Vantagens	Limitações
Support Vector Machine - SVM	91,49		Bom desempenho com dados espectrais distintos	Demanda ajuste fino para o agrupamentos das classes categorizadas
Random Trees ou Random Forest	98,45		Alta robustez; tolerância a sobreajuste	Sensível a amostragem de treinamento desbalanceada
Reconhecimento de feições por CNN	72,23		Extração de padrões complexos espaciais	Necessita grande volume de dados e poder computacional

Figura 3 – Comparação dos métodos de classificação empregados

5. Discussão e Conclusão

A principal meta alcançada nesta proposta de investigação foi a contribuição com a metodologia factível para a avaliação da sensibilidade ambiental ao óleo em áreas costeiras, a qual se fundamentou em métodos de classificação automática de produtos de sensoriamento remoto. Assim, através do uso de tais produtos, foram analisadas alternativas de procedimentos metodológicos de elaboração de índice de sensibilidade ambiental, como também contribuiu para produção de CARTAS SAO, em diferentes escalas (táticas e operacionais).

De fato, o sensoriamento remoto tem sido amplamente empregado para monitoramento ambiental, planejamento urbano e análise de ecossistemas costeiros, com crescente utilização de técnicas de aprendizado de máquina para lidar com a alta complexidade espectral e espacial das imagens de alta resolução (BYCROFT et al., 2019). Dentre as metodologias de classificação, a Análise Orientada a Objetos (OBIA) se destaca por permitir a segmentação de imagens em unidades significativas (objetos), integrando variáveis espectrais, geométricas e contextuais, o que supera limitações inerentes à análise pixel a pixel, especialmente em ambientes urbanos heterogêneos ou em áreas costeiras com elevada variação de substrato (DURIEUX et al., 2008).

Ao comparar diferentes algoritmos de classificação, Schoeman et al. (2019), evidenciou que a CNN apresentou maior robustez e acurácia (F-score máximo de 0,84), especialmente em imagens de boa qualidade, enquanto o RF mostrou-se mais sensível a variações nas condições de luz e ruído. O uso de CNN dentro de uma estrutura OBIA permitiu capturar padrões espaciais complexos com maior capacidade de generalização, reforçando o papel do deep learning em análises ecológicas não invasivas e em larga escala. Os aspectos positivos destacados pelos autores foram a aplicação prática em ecologia costeira com bioindicadores e metodologia replicável e economicamente viável para monitoramento ambiental. Enquanto que as principais limitações apontam para a variação da acurácia de acordo com a qualidade das imagens (luz, contraste, distúrbios), a baixa transferibilidade dos modelos treinados para diferentes datas e condições e a necessidade de recursos computacionais significativos para CNN. Essas limitações também foram constatadas no presente estudo, para o modelo CNN aplicado ao reconhecimento de feições no estuário de Santos.

Complementarmente, Mukhopadhyay e Maulik (2009) propuseram um método híbrido que combina clustering fuzzy multiobjetivo (via NSGA-II) com classificação

supervisionada por SVM. O método denominado MOGA-SVM identifica automaticamente pontos de alta confiança em imagens de satélite para treinar o classificador, melhorando significativamente a acurácia em comparação com abordagens puramente não supervisionadas (como FCM). Essa estratégia se mostrou eficaz em cenários de incerteza espectral e ausência de rótulos confiáveis, comuns em aplicações urbanas e em monitoramento ambiental multitemporal. A SVM, por sua natureza baseada em margens ótimas de separação, mostrou-se especialmente competente para lidar com conjuntos de dados com sobreposição entre classes. Contudo, os autores destacaram que apesar dos aspectos positivos relacionados ao alto desempenho em dados multiespectrais e complexos, como imagens urbanas e à aplicabilidade em problemas com alta incerteza e sem dados rotulados, houve aspecto negativo como a classificação final depender da consistência das amostras de treinamento. Essa mesma limitação foi observada no presente estudo, devido a complexidade e diversidade das feições geográficas da área estudada. Portanto o presente estudo sugere a obtenção de maior quantidade de amostras para o treinamento do modelo.

Por outro lado, Durieux et al. (2008) aplicaram OBIA para extração de edificações em áreas de expansão urbana acelerada utilizando imagens Spot 5 (com resolução espacial de 2,5 m) combinadas com dados vetoriais do SIG. A segmentação orientada por crescimento de regiões e o uso de métricas espectrais, texturais e contextuais permitiram uma classificação semiautomática eficiente, próxima à qualidade da fotointerpretação manual. Embora a abordagem tenha mostrado limitações em identificar o número exato de edificações em imagens de média resolução, os resultados foram suficientemente precisos para subsidiar políticas públicas de ordenamento territorial em áreas de ocupação rápida, como a Ilha da Reunião. Esses autores ainda destacaram que o modelo apresenta limitações em identificar edificações com precisão em áreas densas e que o modelo também requer edição manual de objetos mal classificados (pós-processamento intensivo).

No presente estudo, o modelo de classificação que obteve melhor desempenho foi o RF. Dessa forma, os resultados observados estão alinhados com os estudos relatando que o RF é eficiente e de rápida implementação em projetos com menor disponibilidade computacional, e que o SVM é eficaz quando aplicado com amostras de treino selecionadas com precisão, como no caso do método.

6. Execução das atividades

6.1 Cronograma de atividades realizadas

Atividades	Bimestre											
	1	2	3	4	5	6	7	8	9	10	11	12
Revisão bibliográfica referente as metodologias existentes, síntese e comparação												
Seleção e aquisição de material e elaboração do banco de dados do projeto, em ambiente SIG												
Processamento dos produtos de sensoriamento remoto												
Elaboração de chave de interpretação em SIG utilizado no mapeamento e trabalho de campo												
Aplicação de métodos de classificação automáticas de imagens												
Validação e aprimoramento da metodologia												
Análise dos resultados												
Elaboração de relatório												

Referências

ANTUNES, A. F. B. **Classificação de ambiente ciliar baseada em orientação a objeto em imagens de alta resolução espacial.** (Tese Doutorado), Universidade Federal do Paraná - UFPR, Curitiba, 2003.

ARAUJO, S.I.; MUEHE, D. C. E. H.; DA SILVA, G. H. **Manual Básico para elaboração de Mapas de Sensibilidade Ambiental a Derrames de Óleo no Sistema Petrobras: Ambientes Costeiros e Estuarinos.** Rio de Janeiro: Petrobrás, 2002, 133p.

ARAUJO, S. I. **Mapas de Sensibilidade Ambiental a Derrames de Óleo: Ambientes costeiros, estuarinos e fluviais.** Rio de Janeiro: Petrobras, 2006. 166p.

BYCROFT, R; LEON, J. X.; SCHOEMAN, D. Comparing random forests and convoluted neural networks for mapping ghost crab burrows using imagery from an unmanned aerial vehicle. **Estuarine, Coastal and Shelf Science**, v. 224, p. 84-93, 2019.

CASTANEDO, S., JUANES, J. A., MEDINA, R., PUENTE, A., FERNANDEZ, F., OLABARRIETA, M., & POMBO, C. Oil spill vulnerability assessment integrating physical, biological and socio-economical aspects: Application to the Cantabrian coast (Bay of Biscay, Spain). **Journal of environmental management**, v. 91, n. 1, p. 149-159, 2009.

COMANICU, D.; MEER P. Mean shift: A robust approach toward feature space analysis. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 24 (5), May 2002.

COSTA, S. M. F. **Metodologia Alternativa para o Estudo do Espaço Urbano, Integrando as Tecnologias de SIG e Sensoriamento Remoto - Aplicação à Área Metropolitana de Belo Horizonte.** (Tese de Doutorado). São Paulo: Escola Politécnica da Universidade de São Paulo, 1996.

D'AFFONSECA, F. M. et al. Environmental sensitivity index maps to manage oil spill risks: A review and perspectives. *Ocean & Coastal Management*, v. 239, p. 106590, 2023.

DURIEUX, L.; LAGABRIELLE, E.; NELSON, A. A method for monitoring building construction in urban sprawl areas using object-based analysis of Spot 5 images and existing GIS data. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 63, n. 4, p. 399-408, 2008.

FENG Q., AN C., CHEN, Z., OWENS, E., NIU, H., & WANG, Z. Assessing the coastal sensitivity to oil spills from the perspective of ecosystem services: A case study for Canada's pacific coast. **Journal of Environmental Management**, v. 296, p. 113240, 2021.

GOODCHILD, M. F. Geographical data modeling. **Computers & Geosciences**, v. 18, n. 4, p. 401-408, 1992.

HAMID, B.; MASSINISSA, B.; NABILA, G. Landslide susceptibility mapping using GIS-based statistical and machine learning modeling in the city of Sidi Abdellah, Northern Algeria. **Modeling Earth Systems and Environment**, v. 9, n. 2, p. 2477-2500, 2023.

HUANG, C.; DAVIS, L. S.; TOWNSHEND, J. R. G. An assessment of support vector machines for land cover classification. **International Journal of Remote Sensing**, v. 23 (4), 725-749, 2002. DOI: 10.1080/01431160110040323.

IPIECA. A guide to contingency planning for oil spills on water. **International Petroleum Industry Environmental Conservation Association**, 2(March), 1–32, 2000. [http://doi.org/10.1016/0267-3649\(86\)90011-7](http://doi.org/10.1016/0267-3649(86)90011-7).

JENSEN, J. R. et al. A system approach to environmental sensitivity index (ESI) mapping for oil spill contingency planning and response. **Photogrammetric Engineering & Remote Sensing**, v. 64 (10), p. 1003-1014, 1998.

LAMPARELLI, M. L.; COSTA, M. P.; PRÓSPERI, V. A.; BEVILÁCQUA, J. E.; ARAÚJO, R. P. A.; EYSINK, G. G.; POMPÉIA, S. Sistema estuarino de Santos e São Vicente. Relatório Técnico CETESB. 2001.

LILLESAND, T.M.; KIEFER, R.W. **Remote Sensing and Image Interpretation**. New York: John Wiley & Sons, 2000.

LIU, Y.; GUO, Q.; KELLY, M. A framework of region-based spatial relations for non-overlapping features and its application in object based image analysis. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 63, n. 4, p. 461-475, 2008.

MAHESH, B. Machine learning algorithms-a review. **International Journal of Science and Research (IJSR)**, v. 9, p. 381-386, 2020.

MMA Especificações e Normas Técnicas para a Elaboração de Cartas de Sensibilidade Ambiental para derramamentos de óleo. 22p, 2002.

MEER, P., GEORGESCU, B. Edge detection with embedded confidence. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 23 (12), December 2001.

MENESES, P. R.; ALMEIDA, T. D. **Introdução ao processamento de imagens de sensoriamento remoto**. Brasília: Universidade de Brasília, 2012.

MUKHOPADHYAY, A.; MAULIK, U. Unsupervised pixel classification in satellite imagery using multiobjective fuzzy clustering combined with SVM classifier. **IEEE transactions on geoscience and remote sensing**, v. 47, n. 4, p. 1132-1138, 2009.

NELSON, J. R.; GRUBESIC, T. H. Oil spill modeling: risk, spatial vulnerability, and impact assessment. **Progress in physical geography: earth and environment**, v. 42, n. 1, p. 112-127, 2018.

NOAA. **Sensitivity mapping of inland areas: Technical support to the inland Area Planning Committee Working Group**. USEPA Region 5. Seattle: NOAA, Hazardous Materials Response and Assessment Division, HAZMAT Report 95-4. 54pp.+appendix., 1995.

O'BRIEN-DELPESH, C., SINANAN, N., MARTIN, H., CHADEE, A. Preserving fragile ecosystems from oil spills—An environmental sensitivity assessment of the east coast of Trinidad. **Ocean & Coastal Management**, v. 230, p. 106374, 2022.

POFFO, I. R. F. Gerenciamento de riscos socioambientais no Complexo Portuário de Santos na ótica ecossistêmica. 2007. 157 f. Tese (Doutorado em Ciências Ambientais). PROCAM. Universidade de São Paulo. São Paulo. 2007.

RENK, M. Transporte e armazenamento de hidrocarbonetos em áreas costeiras: um estudo sobre percepção de riscos em municípios do litoral norte paulista. 2016 (Tese de Doutorado). Universidade Estadual de Campinas, São Paulo.

ROCHA, M. L. C. F. Indicadores ecológicos e biomarcadores de contaminação ambiental na ictiofauna da Baía de Santos e do Canal de Bertiooga, São Paulo, Brasil. 2009. 208 f. Dissertação (Mestrado em Oceanografia Biológica). Universidade de São Paulo, Instituto Oceanográfico, São Paulo. 2009.

RODRIGUEZ-GALIANO, V. F, GHIMIRE, B, ROGAN J, CHICA-OLMO M, RIGOL-SANCHEZ, J. P. An assessment of the effectiveness of a Random Forest classifier for land-cover classification. **ISPRS Journal of Photogrammetry and Remote Sensing**, 67:93–104. 2012. <https://doi.org/10.1016/j.isprsjprs.2011.11.002>.

SCHILLER, H., VAN BERNEM, C., KRASEMANN, H. L. Automated classification of an environmental sensitivity index. **Environmental monitoring and assessment**. 110, 291–299, 2005. <https://doi.org/10.1007/s10661-005-8041>.

SUGUIO, K. **Dicionário de geologia marinha**: com termos correspondentes em inglês, francês e espanhol. São Paulo: Ed. T. A. Queiroz, 1992.

SUGUIO, K.; MARTIN, L. **Formações quaternárias marinhas do litoral paulista e sul fluminense**: Quaternary marine formations of the state of São Paulo and southern Rio de Janeiro. Special Publication, n. 1, 1978.

VENANCIO, K, K. Evolução hidromorfodinâmica da região da Ponta da Praia em Santos – SP, no período entre 2009 e 2017. Dissertação de Mestrado apresentada à Faculdade de Engenharia Civil, Arquitetura e Urbanismo da Unicamp. Campinas 2018.

WIECKZOREK, A. **Mapeamento de Sensibilidade a Derramamentos de Petróleo do Parque Estadual da Ilha do Cardoso – PEIC e Áreas do Entorno**. Tese (Mestrado em Geociências e Meio Ambiente) - Instituto de Geociências e Ciências Exatas, Universidade Estadual Paulista, Rio Claro, 2006.

7. Produção bibliográfica

➤ Organização e produção dos capítulos dos livros

○ Volume I - Carta SAO: conceitos, tipos e procedimentos metodológicos

1. MARQUES, M. L.; GIORDANO, L. C. Estruturação de Banco de Dados Espacial para Cartas SAO. In: Paulina Setti Riedel; Daiana Marques Costa; Lucilia do Carmo Giordano; Arthur Wieczorek; Mara Lúcia Marques; Fábio Augusto Gomes Vieira Reis. (Org.). Cartas SAO Sensibilidade Ambiental ao Óleo: conceitos, tipos e procedimentos metodológicos. 1ed.Rio Claro - SP: UNESPetro/IGCE/UNESP, 2023, v. 1, p. 137-154. (em Anexo)
2. GIORDANO, L. C.; WIECZOREK, A.; MARQUES, M. L.; COSTA, D. M.; RODRIGUES, F. H.; KOLYA, A. A.; RIEDEL, P. S. Metodologia de Elaboração das Cartas SAO. In: Paulina Setti Riedel; Daiana Marques Costa; Lucilia do Carmo Giordano; Arthur Wieczorek; Mara Lúcia Marques; Fábio Augusto Gomes Vieira Reis. (Org.). Cartas SAO Sensibilidade Ambiental ao Óleo: conceitos, tipos e procedimentos metodológicos. 1ed.Rio Claro - SP: UNESPetro/IGCE/UNESP, 2023, v. 1, p. 121-136. (em Anexo)
3. WIECZOREK, A.; MARQUES, M. L.; SANTOS, S. F.; VEIGA, V. M.; Aspectos Socioeconômicos e Bióticos. In: Paulina Setti Riedel; Daiana Marques Costa; Lucilia do Carmo Giordano; Arthur Wieczorek; Mara Lúcia Marques; Fábio Augusto Gomes Vieira Reis. (Org.). Cartas SAO Sensibilidade Ambiental ao Óleo: conceitos, tipos e procedimentos metodológicos. 1ed.Rio Claro - SP: UNESPetro/IGCE/UNESP, 2023, v. 1, p. 89-120. (em Anexo)

○ Volume II - Carta SAO: aplicações

1. GIORDANO, L.C.; COSTA, D. M.; RODRIGUES, F. H.; WIECZOREK, A.; MARQUES, M. L.; CORREA, C. V. S. ; VEIGA, V. M. ; SANTOS, S. F. ; REIS, F. A. G. V. ; Riedel, Paulina Setti . Baía de Babitonga - São Francisco do Sul. In: Fábio Augusto Gomes Vieira Reis; Daiana Marques Costa; Lucilia do Carmo Giordano; Arthur Wieczorek; Mara Lúcia Marques; Claudia Vanessa dos Santos Corrêa; Paulina Setti Riedel. (Org.). CARTA SAO - SENSIBILIDADE AMBIENTAL AO ÓLEO: APLICAÇÕES. 1ed.Rio Claro - SP: UNESPetro/IGCE/UNESP, 2023, v. 2, p. 165-190. (em Anexo)

2. GIORDANO, L. C. ; COSTA, D. M. ; RODRIGUES, F. H. ; WIECZOREK, A. ; MARQUES, M. L.; CORREA, C. V. S. ; VEIGA, V. M. ; SANTOS, S. F. ; REIS, F.A.G.V. ; RIEDEL, P. S . Baía de Paranaguá. In: Fáblio Augusto Gomes Vieira Reis; Daiana Marques Costa; Lucilia do Carmo Giordano; Arthur Wieczorek; Mara Lúcia Marques; Claudia Vanessa dos Santos Corrêa; Paulina Setti Riedel. (Org.). CARTA SAO - SENSIBILIDADE AMBIENTAL AO ÓLEO: APLICAÇÕES. 1ed.Rio Claro - SP: UNESPetro/IGCE/UNESP, 2023, v. 2, p. 141-164. (em Anexo)
3. KOLYA, A. A. ; COSTA, D. M. ; RODRIGUES, F. H. ; WIECZOREK, A. ; MARQUES, M. L.; CORREA, C. V. S. ; GIORDANO, L.C.; SANTOS, S. F.; VEIGA, V. M. ; RIEDEL, P. S . Baía da Ilha Grande. In: Fáblio Augusto Gomes Vieira Reis; Daiana Marques Costa; Lucilia do Carmo Giordano; Arthur Wieczorek; Mara Lúcia Marques; Claudia Vanessa dos Santos Corrêa; Paulina Setti Riedel. (Org.). CARTA SAO - SENSIBILIDADE AMBIENTAL AO ÓLEO: APLICAÇÕES. 1ed.Rio Claro - SP: UNESPetro/IGCE/UNESP, 2023, v. 2, p. 65-90. (em Anexo)
4. RODRIGUES, F. H.; KOLYA, A. A.; WIECZOREK, A.; MARQUES, M. L.; CORREA, C. V. S.; COSTA, D. M.; GIORDANO, L.C.; SANTOS, S. F. ; VEIGA, V. M. ; RIEDEL, P. S . Baía de Guanabara. In: Fáblio Augusto Gomes Vieira Reis; Daiana Marques Costa; Lucilia do Carmo Giordano; Arthur Wieczorek; Mara Lúcia Marques; Claudia Vanessa dos Santos Corrêa; Paulina Setti Riedel. (Org.). Cartas SAO SENSIBILIDADE AMBIENTAL AO ÓLEO APLICAÇÃO. 1ed.Rio Claro - SP: UNESPetro/IGCE/UNESP, 2023, v. 2, p. 15-40. (em Anexo)
5. RODRIGUES, F. H.; KOLYA, A. A.; SANTOS, S. F.; WIECZOREK, A.; MARQUES, M. L.; CORREA, C. V. S. COSTA, D. M.; GIORDANO, L.C.; VEIGA, V. M.; RIEDEL, P. S. Baía de Sepetiba. In: Fáblio Augusto Gomes Vieira Reis; Daiana Marques Costa; Lucilia do Carmo Giordano; Arthur Wieczorek; Mara Lúcia Marques; Claudia Vanessa dos Santos Corrêa; Paulina Setti Riedel. (Org.). CARTA SAO - SENSIBILIDADE AMBIENTAL AO ÓLEO: APLICAÇÕES. 1ed.Rio Claro - SP: UNESPetro/IGCE/UNESP, 2023, v. 2, p. 41-64. (em Anexo)
6. WIECZOREK, A.; RODRIGUES, F. H.; MARQUES, M. L.; CORREA, C. V. S.; COSTA, D. M.; KOLYA, A. A.; GIORDANO, L.C.; VEIGA, V. M. SANTOS, S. F.; RIEDEL, P. S. Enseada de Caraguatatuba. In: Fáblio Augusto Gomes Vieira Reis; Daiana Marques Costa; Lucilia do Carmo Giordano; Arthur Wieczorek; Mara Lúcia Marques; Claudia Vanessa dos Santos Corrêa; Paulina Setti Riedel. (Org.). CARTA SAO - SENSIBILIDADE AMBIENTAL AO ÓLEO: APLICAÇÕES. 1ed.Rio Claro - SP: UNESPetro/IGCE/UNESP, 2023, v. 2, p. 91-114. (em Anexo)
7. WIECZOREK, A.; COSTA, D. M.; RODRIGUES, F. H.; MARQUES, M. L.; KOLYA, A. A.; CORREA, C. V. S. ; GIORDANO, L.C.; VEIGA, V. M.; SANTOS, S. F.; GUERRA, F. C.; RIEDEL, P. S . Estuário de Santos. In: Fáblio Augusto Gomes Vieira Reis; Daiana Marques Costa; Lucilia do Carmo Giordano; Arthur Wieczorek; Mara Lúcia Marques; Claudia Vanessa dos Santos Corrêa; Paulina Setti Riedel.

(Org.). CARTA SAO - SENSIBILIDADE AMBIENTAL AO ÓLEO: APLICAÇÕES. 1ed.Rio Claro - SP: UNESPetro/IGCE/UNESP, 2023, v. 2, p. 115-140. (em Anexo)

- Elaboração e submissão de artigos
 - Digital big data management to police environmental sustainability damage associated to the petroleum industry processes (em Anexo)
 - Comparação entre métodos machine learning na classificação da cobertura e uso do solo para elaboração do Índice Sensibilidade Ambiental (manuscrito em desenvolvimento)

- Participação em evento científico

XI GEO Políticas: Pesquisa e Desenvolvimento nos setores de Petróleo e Geodiversidade. 2023.