

MAPEAMENTO DO ÍNDICE DE SENSIBILIDADE NO LITORAL DA GUINÉ-BISSAU POR GEOBIA E *MACHINE LEARNING*

Jairson Alberto Sami^{@ 1}, Cristiane Nunes Francisco¹, Pedro José Farias Fernandes¹, Tiago Fernando de Holanda¹

RESUMO: Este trabalho tem como objetivo gerar o Índice de Sensibilidade do Litoral (ISL) ao derramamento de óleo na costa da Guiné-Bissau. Localizada na zona tropical da África Ocidental, a Guiné-Bissau possui uma extensa zona costeira, com predominância de amplitude de maré alta, que influencia o interior do continente até 150 km, com 22% do território inundado durante a estação chuvosa. A metodologia foi baseada nas Especificações e Normas Técnicas para a Elaboração das Cartas de Sensibilidade Ambiental a Derramamentos de Óleo (Cartas SAO), desenvolvida pelo Ministério de Meio Ambiente (MMA) do Brasil, utilizando a análise de imagens baseada em objetos geográficos (GEOBIA) e aprendizado de máquina para classificação da cobertura da terra em uma imagem Sentinel (maio de 2020). Após a segmentação da imagem e coleta de amostras, foram extraídos atributos da imagem (média e desvio padrão das bandas espectrais e índices de vegetação). A precisão de diferentes algoritmos de aprendizado de máquina foi avaliada (*Random Forest*, *Support Vector Classifier*, *Gradient Boosting* e *Multilayer Perceptron*). O algoritmo *Random Forest* apresentou o maior acurácia (0.97) e foi utilizado para a classificação final da cobertura da terra, que foram reclassificadas para valores de ISL. A área de estudo apresenta valores de ISL variando de 3 a 10. No entanto, os índices mais altos (8, 9 e 10) representaram 94.4% da área mapeada e são consideradas as unidades onde é mais difícil remover o óleo. Considerando a vulnerabilidade do país à exposição de petroleiros que atravessam o Golfo de Guiné, o ISL é uma ferramenta importante na mitigação dos danos ambientais causados por derramamentos de óleo na costa guineense.

Palavras-chave: risco de derramamento de óleo, gerenciamento costeiro, mangue, aprendizagem de máquina, processamento de imagem.

ABSTRACT: This work aims to generate the map of the Coastal Sensitivity Index (CSI) to oil spill for an area in the Guinea-Bissau coast. Located in the tropical zone of West Africa, Guinea-Bissau has an extensive coastal zone, with a predominance of high tide amplitude, which influences the interior of the continent by up to 150 km, causing around 22% of the territory to be flooded during the rainy season. The methodology was based on the Technical Specifications and Standards for the Preparation of Environmental Sensitivity Charts for Oil Spills in Brazil (SAO Charts), developed by the Brazilian Ministry of Environmental (MMA), using geographic object-based image analysis (GEOBIA) and machine learning for land cover classification of a Sentinel image (May 2020). After image segmentation and sample collection, image attributes were extracted (mean and standard deviation of spectral bands and vegetation indices). The accuracy of different machine learning algorithms was evaluated (*Random Forest*, *Support Vector Classifier*, *Gradient Boosting* and *Multilayer Perceptron*). The *Random Forest* algorithm presented the highest accuracy (0.97) and was used for the final land cover classification, that were reclassified to CSI values. The study area shows CSI values ranging from 3 to 10. However, the highest indices (8, 9 and 10) represented 94.4% of the mapped area and are considered as the most difficult units to remove oil. Considering the country's vulnerability to the exposure of oil tankers crossing the Gulf of Guinea, the CSI is an important tool in mitigating environmental damage caused by oil spills in the Guinean coast.

Keywords: oil spillage risk, coastal environment management, mangrove, machine learning, image processing.

@ Corresponding author: jairsonalberto@id.uff.br

1 Universidade Federal Fluminense

1. INTRODUÇÃO

A indústria petrolífera teve o seu início no século XIX e consolidou-se no século XX, tornando-se um dos principais setores económicos do mundo. No entanto, apesar dos grandes avanços tecnológicos verificados no setor, os acidentes ainda são recorrentes (Martins *et al.*, 2013) e causam grandes danos aos ecossistemas, com consequências para as populações humanas e para a economia (Nwilo & Badejo, 2006).

Apesar da redução do derramamento de óleo a nível mundial, devido aos avanços tecnológicos e à melhoria de condições de segurança do transporte marítimo, o risco ainda é considerado alto, visto que nos últimos anos houve um aumento significativo do comércio de petróleo a nível mundial. As principais rotas dos navios petroleiros situam-se no Oceano Atlântico, a oeste da Europa, onde ocorreram 57% dos principais acidentes registados nos últimos 50 anos, enquanto, nas águas próximas da África do Sul, apenas 13%, assim como no continente americano, enquanto os 17% restantes ocorreram em águas asiáticas (Galieriková & Materna, 2020).

Nos últimos anos, a indústria petrolífera tem investido em pesquisas em África, devido aos resultados encorajadores obtidos no Golfo da Guiné e na bacia do Congo, bem como em outras áreas do continente. Observa-se que, em quase todos os países africanos, já está em atividade a exploração ou a produção de petróleo (Graham & Ovadia, 2019). Segundo os dados da *United States Energy Information Administration* (EIA), as reservas petrolíferas existentes em África cresceram mais de 240% entre 1980 e 2013.

Segundo a ANEME (2018), Guiné-Bissau não dispõe de petróleo viável comercialmente, no entanto, a sua presença na costa offshore está comprovada, bem como já há concessionárias operando nas atividades exploratórias. Além disso, com as descobertas de grandes reservas de petróleo nos países vizinhos, localizados na mesma formação geológica -Senegal, Mauritânia e Gâmbia, acredita-se que possa haver viabilidade comercial.

No entanto, apesar dos dados sobre derramamentos de óleo na costa da Guiné-Bissau serem escassos, esse país está situado em uma área de risco de acidentes de óleo, pois, na região da África Ocidental, encontram-se grandes países produtores de petróleo, tais como Nigéria, Costa do Marfim, Gana e Mauritânia. O intenso tráfego de navios e de petroleiros que atravessam sua costa, associado aos desafios enfrentados por países vizinhos, sugerem um risco indireto para o país. A Nigéria,

inclusive, registra um histórico de frequentes derramamentos de óleo, decorrente tanto da extração quanto do transporte de petróleo, exacerbados por atividades de pirataria, sabotagem e infraestrutura envelhecida. Entre 1976 e 2019, ocorreram mais de 12 mil eventos na Nigéria, principalmente na região do Delta do Níger, causando danos ambientais de grande escala (Graham & Ovadia, 2019; Nwilo & Badejo, 2006).

Os estudos sobre o mapeamento do derramamento de óleo e a avaliação dos impactos iniciaram-se na década de 1970 pelo grupo de pesquisadores da Divisão de Pesquisa Costeira do Departamento de Geologia da Universidade da Carolina do Sul, nos Estados Unidos (Hayes *et al.*, 1977). A Carta SAO - Cartas de Sensibilidade Ambiental a Derramamentos de Óleo, criada na mesma década, tornou-se uma importante ferramenta técnico-gerencial para priorização dos ambientes sensíveis visando a proteção da costa e redução dos impactos em caso de acidentes com derrame de óleo (Michel *et al.*, 1978). Martins *et al.* (2013) referem que existem várias metodologias para elaboração das Cartas SAO, que usam o cálculo matricial para avaliar, com base na sensibilidade dos ecossistemas, os impactos culturais, os tipos de costa, os impactos económicos, entre outros fatores.

A metodologia da Carta SAO, conforme as Especificações e Normas Técnicas para a Elaboração das Cartas SAO, desenvolvida pelo Ministério de Meio Ambiente (MMA) para o Brasil, é baseada em três informações principais: recursos biológicos, usos humanos dos espaços e recursos (atividades socioeconómicas) e sensibilidade dos ecossistemas costeiros e marinhos, sendo que este último incorpora o Índice de Sensibilidade ao Litoral - ISL (Brasil, 2002). Este índice, a mais importante informação da metodologia, é responsável por medir a sensibilidade do ambiente costeiro ao óleo em relação às características geomorfológicas - hidrodinâmica, substrato e declividade do litoral; e às características biológicas - vegetação e animais (Marinho & Nicolodi, 2019; Brasil, 2002).

A maioria dos métodos de classificação de ISL são derivados da *National Oceanic and Atmospheric Administration* - NOAA, que classifica a sensibilidade da costa de acordo com as características geomorfológicas, sensibilidade a derramamentos de óleo, persistência natural do óleo e condições de limpeza e remoção do óleo (Jensen *et al.*, 1998; Brasil, 2002). Os costões rochosos são classificados com sensibilidade de 1 a 2, as praias arenosas, de 3 a 6, e as planícies de maré arenosa ou lamosa e margens vegetadas, classificadas de 7 a 10 (Marinho & Nicolodi, 2019; Brasil, 2002).

A metodologia desenvolvida no Brasil para geração do ISL também deriva da NOAA, mas com ligeiras adaptações à realidade local. Mantém-se a escala, porém com variações na atribuição do índice às feições costeiras. Acrescenta-se, também, que os valores da escala não representam a quantificação absoluta da sensibilidade ao óleo, por exemplo: o índice ISL 6 não é seis vezes mais sensível do que o ISL 1 (Brasil, 2002).

Graham & Ovadia (2019) referem-se às leis que regulamentam a indústria petrolífera nos países africanos, que entraram nos últimos anos na exploração e produção de petróleo, como frágeis ou quase inexistentes sob a ótica ambiental. Como o Brasil tem um ambiente tropical semelhante ao da África Ocidental (Christopher *et al.*, 2021; Aragão *et al.*, 2021), acredita-se que as leis ambientais brasileiras podem servir de base para esta região da África e, entre elas, a necessidade da elaboração das Cartas SAO.

Muitos estudos empregam Sistemas de Informação Geográfica (SIG) para implementar as normas que regulamentam a elaboração da Carta SAO em diferentes países (Marinho *et al.*, 2021; Marinho & Nicolodi, 2019; Aps *et al.*, 2016; Pincinato *et al.*, 2009). Pincinato *et al.* (2009) propõem uma abordagem de classificação automatizada através dos SIG para gerar ISL. Esta proposta também considera a sazonalidade no habitat quanto à sensibilidade do óleo, pois como as condições ambientais e a sua relevância mudam durante o ano, o ISL precisa ser adaptado a cada estação.

O sensoriamento remoto também constitui uma importante fonte de dados para a elaboração da Carta SAO, uma vez que permite o mapeamento e detecção das mudanças no uso e cobertura de terra (Arvor *et al.*, 2013; El Mahradi *et al.*, 2020). El Mahradi *et al.* (2020) mostram que a evolução da contribuição de sensoriamento remoto no mapeamento e gestão ambiental costeira e marinha, principalmente os dados obtidos por satélite, possuem a vantagem de mapear grandes áreas com base em séries temporais longas e grande volume de informações espectrais, além de ter um custo menor em comparação a outros meios remotos. Muler *et al.* (2011) também apontam que o uso das geotecnologias constitui uma ferramenta de grande relevância para o estudo das zonas costeiras, pois permite a rapidez e a exatidão na obtenção dos dados que auxiliam na tomada de decisão sobre os diversos problemas do litoral.

O grande volume de dados obtidos nos últimos anos em sensoriamento remoto tornou necessário um processamento robusto, preciso e eficaz. A busca incessante para atender a essa demanda proporcionou aplicações de algoritmos de *machine*

learning (aprendizagem de máquina) para a classificação de imagens multiespectrais (Hänsch, 2020). Além disso, há aplicações bem sucedidas na literatura de sensoriamento remoto de *machine learning* em conjunto com GEOBIA (*Geographic object-based image analysis*) na classificação de imagens (Xie & Niculescu, 2021; Maxwell *et al.*, 2015).

Beneditti *et al.* (2016) afirmam que as áreas litorais, em geral, são consideradas muito sensíveis ao derramamento de óleo, assim a prevenção e a criação de medidas mitigadoras do derramamento de óleo na zona costeira guineense são de extrema importância. Além disso, Guiné-Bissau possui uma lacuna científica nesta temática, pois há poucos trabalhos produzidos.

Desta forma, este estudo tem como objetivo determinar o Índice de Sensibilidade ao Litoral (ISL) ao derramamento de óleo para Guiné-Bissau com a aplicação da metodologia proposta nas Especificações e Normas Técnicas para Elaboração de Cartas de Sensibilidade Ambiental para Derramamentos de Óleo, desenvolvida no Brasil no ano 2002. Para isso, foi gerado um mapa de cobertura da terra através da classificação de imagens de satélite por análise baseada em objetos geográficos (GEOBIA), com base em algoritmos de aprendizagem de máquina, a fim de indicar a sensibilidade ao óleo no litoral.

2. ÁREA DE ESTUDO

A área de estudo (Figura 1) é representativa da costa da Guiné-Bissau, um país com relevo plano a suave ondulado, situado na zona costeira oeste do continente africano, formada por uma parte continental e um conjunto de mais 88 ilhas e ilhéus (ANEME, 2018). Situado na região tropical, apresenta duas estações no ano, a chuvosa, que começa em meados de maio e termina em meados de novembro e, a seca, que corresponde aos seis meses restantes (Weather Spark, 2022).

Segundo a projeção da Organização das Nações Unidas (ONU) para 2022, a população guineense é de 2 milhões de habitantes (ONU, 2022). A maioria vive na zona litorânea, e a capital do país, Bissau, a mais populosa, alberga aproximadamente 25% dos habitantes (Fandé *et al.*, 2020). A população guineense é muito dependente do litoral, apenas a região de Gabú situa-se exclusivamente no interior, com a sua economia baseada na agricultura e pesca. As áreas do litoral, como são inundadas periodicamente, na sua maioria, são compostas por campos e cultivo de arroz das comunidades tradicionais (ANEME, 2018).




Figura 1. Localização da área de estudo.

O litoral guineense é caracterizado pela baixa altitude, com maior parte do território localizado abaixo de 40 m e, máxima altitude, de 300 m, correspondente à colina de Boé (Banco Mundial, 1992). Dos 36.1 mil km² que compõem o território nacional, 77% são superfícies emersas, e o restante fica total ou parcialmente inundado em alguma época do ano. A baixa declividade do terreno associada à predominância de elevada amplitude das marés fazem com que os seus efeitos sejam sentidos até 150 km para o interior do continente. As planícies costeiras são recortadas por um sistema complexo de canais, onde os principais rios do país - Cacheu, Geba e Corubal, que drenam os planaltos no interior, atravessam e desaguam em largos estuários, invadidos periodicamente pela maré (Banco Mundial, 1992).

No presente artigo, a zona costeira foi delimitada com base na cota 10 m do MDE Copernicus, que abrange 7.9 mil km² e corresponde a 22% do território nacional guineense (Figura 2). ANEME (2018) indica que 23% do território da Guiné-Bissau está parcial ou completamente inundado em algum período do ano, devido à penetração da maré no interior do continente e às ocorrências de chuvas, aumentando a vulnerabilidade das residências construídas nas zonas úmidas/litorâneas de Guiné-Bissau (Fandé *et al.*, 2020).

A vegetação é dividida em três principais zonas: litoral - composto por mangue; palmares de transição - formada de mistura de floresta e savana; e interior - dominado pelas savanas arbóreas e gramíneas (Banco Mundial, 1992). Na extensa faixa litoral guineense, observam-se oito espécies de mangue: *Acrostichum aureum*, *Avicennia germinans*, *Conocarpus erectus*, *Laguncularia racemosa*, *Machaerium lunatum*, *Rhizophora mangle*, *R. harrisoniae* e *R. racemosa* (Banco Mundial, 1992), sendo que a *Avicennia* e a *Rhizophora mangleas* são as espécies dominantes (UNEP, 2007).

Esta floresta constitui uma das áreas mais ricas da África Ocidental no que diz respeito à diversidade e produtividade biológica (Maretti, 2002). O manguezal é um dos principais ecossistemas de transição que estabiliza a linha costeira e reduz impactos ambientais, fundamental para a manutenção da costa. No entanto, devido ao excesso de exploração, torna-se um dos ecossistemas mais ameaçados do mundo (Viegas *et al.*, 2019), além de também ser considerado sensível às mudanças bruscas, entre elas, causadas por vazamento do petróleo e derivados (Beneditti *et al.*, 2016).




Figura 2. Modelo Digital de Elevação da Guiné-Bissau.

A particularidade do ecossistema costeiro guineense e o seu papel na conservação das espécies têm muita relevância na conservação da fauna, como é o caso de aves migratórias, golfinhos, hipopótamos e tartarugas. A Guiné-Bissau é frequentada por três espécies de tartarugas-marinhas: a tartaruga-de-pente (*Eretmochelys imbricata*), a tartaruga-olivácea (*Lepidochelys olivacea*) e tartaruga-verde (*Chelonia mydas*), sendo que esta última está em perigo de extinção (IBAP, 2022).

Segundo o IBAP (2022), 23% do território nacional é constituído por áreas protegidas, na qual $\frac{2}{3}$ correspondem a espaços marinhos ou estuarinos. Ressalta-se que no delta do Cacheu, situado no Parque Natural dos Tarrafes de Cacheu, destinado à preservação de mangue, encontra-se o maior bloco contínuo de manguezal da África Ocidental, que corresponde a 66% do mangue existente na Guiné-Bissau (Rabelo *et al.*, 2018).

3. MATERIAIS E MÉTODOS

O presente estudo focou-se na cena do Sentinel localizada nas coordenadas 12°43'48.9"N, 15°55'31.8"W e 11°42'08.3"N,

15°00'25.9"W na zona litoral guineense (Figura 1), constituída por uma área plana localizada entre a linha de costa até a altitude de 7 m, correspondente a área atingida pela maré média em Guiné-Bissau (Tábua de Maré, 2022). Considerando o aumento da magnitude dos eventos extremos (Barry *et al.*, 2018), face às alterações climáticas, bem como a forte ruptura de declive entre a planície e as encostas abruptas do relevo, considerou-se a cota de 10 m como limite da zona costeira em estudo (Figura 2).

3.1. Materiais

Neste trabalho, foram utilizadas as imagens do satélite Sentinel-2/ MIS de maio de 2020 (mês correspondente ao auge do período seco da região para facilitar a discriminação da vegetação) disponíveis na página do *United States Geological Survey* (USGS). Foram transferidas as seguintes bandas espectrais: B02 - azul (Blue) 490 nm, B03 - verde (Green) 560 nm, B04 - vermelho (Red) 665 nm, B08 - infravermelho próximo (NIR) 842 nm; e B011 - infravermelho de ondas curtas (SWIR) 1.610 nm. As imagens do Sentinel-2 apresentam a maior resolução espacial, entre as imagens gratuitas disponíveis (bandas do visível e a NIR com 10 m e banda do SWIR com 20 m).

Como dados auxiliares, foram utilizados o Modelo Digital de Elevação (MDE) Copernicus, com resolução espacial de 10 m, adquirido no repositório de dados PANDA (Planetary Data Access) da Agência Espacial Europeia (ESA) para a delimitação da zona costeira; e também as imagens SAR/Sentinel-1 de maio de 2020 na polarização VH, modo de aquisição IW com 10 m de resolução espacial, órbita descendente, para a discriminação dos corpos de águas no ambiente *Google Earth Engine* (Gorelick *et al.*, 2017).

3.2. Métodos

Os procedimentos metodológicos (Figura 3) consistiram nas etapas que visaram a geração de um mapa de cobertura da terra, através de GEOBIA e classificação via *machine learning*, para, por fim, associá-lo ao ISL

A primeira etapa constituiu no pré-processamento dos dados georreferenciados e o cálculo dos índices espectrais; a segunda consistiu na segmentação das imagens e extração dos atributos; a terceira correspondeu à classificação dos atributos através de *machine learning*, visando a geração do mapa de cobertura da

terra; por fim, a quarta etapa constitui na geração de ISL com base no mapa classificado.

3.2.1. Pré-processamento de imagens

Foi feito o mosaico das cenas que cobrem a área de estudo dentro do território da Guiné-Bissau, com os *scripts* da linguagem de programação R e uso da biblioteca *raster* (Hijmans *et al.* 2015). A banda B011 (SWIR) foi reamostrada para a mesma resolução espacial das demais bandas, 10 m, pelo método de interpolação do vizinho mais próximo. Posteriormente, foram gerados os seguintes índices de vegetação espectrais (IVs) utilizados para discriminar as classes de cobertura da terra:

Índice de Vegetação por Diferença Normalizada (NDVI) – corresponde à razão normalizada entre as bandas *NIR* e *Red* (Equação 1), a fim de destacar a cobertura vegetal e diferenciá-la das regiões de sombra (Rouse *et al.*, 1974).

$$NDVI = (Red - NIR) / (Red + NIR) \quad (1)$$

Índice de Água por Diferença Normalizada (NDWI) – corresponde à razão normalizada entre as bandas *NIR* e *Green* (Equação 2)




Figura 3. Fluxograma das etapas do trabalho.

a fim de auxiliar na definição de feições de corpos de água (McFeeters, 1996).

$$NDWI = (Green - NIR) / (Green + NIR) \quad (2)$$

Índice de Água por Diferença Normalizada Modificado (MNDWI) - corresponde à razão normalizada entre as bandas *Green* e *SWIR* (Equação 3), para facilitar a delimitação de áreas inundadas (Brubacher *et al.*, 2017).

$$MNDWI = (Green - SWIR) / (Green + SWIR) \quad (3)$$

Índice Modular de Reconhecimento de Mangue (MMRI) corresponde à razão normalizada entre os *MNDWI* e *NDVI* (Equação 4), que facilita a separação da floresta de mangue das demais formações florestais (Diniz *et al.*, 2019).

$$MMRI = |MNDWI| - |NDVI| / |MNDWI| + |NDVI| \quad (4)$$

Além disso, a partir do MDE Copernicus, foram extraídas as curvas de nível da área de estudo, bem como foi utilizado como um atributo para a classificação das imagens (Cremon *et al.*, 2022).

Portanto, no total, a base de dados georreferenciada, utilizada para a realização dos testes de classificação por GEOBIA, foi formada por dez camadas, correspondendo a cinco bandas espectrais (Banda 2, Banda 3, Banda 4, Banda 8 e Banda 11), e quatro índices espectrais (*NDVI*, *NDWI*, *MNDWI* e *MMRI*), além do MDE Copernicus.

3.2.2. Segmentação das imagens e extração dos atributos

A automatização da extração de informações das imagens de sensores remotos, a partir da GEOBIA, corresponde a duas etapas de execução. A primeira etapa, denominada segmentação, consiste em um processo na qual a imagem é repartida em pequenas regiões (objetos) com base em critérios de homogeneidade dos pixels (Gonzalez e Woods, 2009), enquanto a classificação propriamente dita, segunda etapa, consiste em rotular os objetos a partir de seus atributos - espectrais, texturais, forma, contexto e semânticos (Benz *et al.*, 2004). A GEOBIA apresenta algumas vantagens em comparação aos métodos tradicionais, baseados nos pixels, por considerar o objeto como base da análise da imagem, reduz a heterogeneidade interna das entidades a serem mapeadas e disponibiliza atributos de alto nível mais próximos a interpretação humana (Lui *et al.*, 2020; Benz *et al.*, 2004).

No presente trabalho, a segmentação das imagens foi feita no *software* eCognition Developer 9 (Trimble, 2022) a partir do algoritmo de segmentação multirresolução (Baatz & Schape,

2000). Este algoritmo possui como entrada as imagens e seus respectivos pesos referentes à influência no processo de segmentação, além de mais três parâmetros: a escala - medida de heterogeneidade que define o tamanho dos objetos, forma - peso da forma na segmentação, e compacidade - peso da compacidade dos objetos (Baatz & Schape, 2000).

Para definir a configuração de segmentação das imagens, foram feitos testes com base na combinação de diferentes camadas de entrada e parâmetros de segmentação (escala, forma e compacidade). Com base na interpretação visual, os resultados mostraram que as bandas 3, 4 e 8, com pesos iguais, foram as mais apropriadas para a segmentação da área de estudo. Posteriormente, foram realizados mais quatro testes de segmentação, utilizando as bandas selecionadas, visando encontrar a combinação ideal dos parâmetros (Tabela 1). O teste I - escala 150, forma 0.1 e compacidade 0.3 - foi o que apresentou melhor resultado para a área de estudo.



Tabela 1. Parâmetros dos testes de segmentação de imagens Sentinel-2 no eCognition.

Teste	Parâmetro de escala	Forma	Compacidade
I	150	0.1	0.3
II	150	0.1	0.2
III	200	0.1	0.2
IV	100	0.1	0.2

A seguir, foram extraídos os atributos - média (*mean*), mediana (*q50*) e desvio padrão (*sd*), das imagens espectrais, dos IVs e do MDE Copernicus. Os objetos gerados pela segmentação compuseram o banco de dados final, constituído por trinta atributos, a serem utilizados na classificação dos objetos com base nos algoritmos de *machine learning*.

Posteriormente, no sistema *QGIS*, que permite a visualização, a edição e a análise de dados georreferenciados, foram coletadas as amostras de treinamento correspondentes às classes de cobertura da terra. O treinamento corresponde ao processo de aprendizagem sobre os objetos de interesse, com base nas amostras das referidas classes, para que sejam utilizadas pelos algoritmos de classificação supervisionada. A coleta das amostras foi feita manualmente observando os alvos na composição colorida do Sentinel-2 e nas imagens dos índices, assim como no *Google Earth*. Foram coletadas, no mínimo, 200 amostras de objetos gerados pela segmentação para cada classe de cobertura da terra, que estão descritas no Tabela 2.

Tabela 2. Chave de interpretação das classes de cobertura da terra.

Classes	Definição	Sentinel-2 - Composição 234
Áreas descobertas	Áreas construídas, ocupações, praias, dunas e extensões de areia ou seixos no litoral ou no continente, incluindo leitos de canais de fluxo com regime torrencial; dunas com vegetação esparsa ou sem vegetação, desenvolvidas no interior do continente ou nas zonas de praias; áreas de extração abandonadas e sem cobertura vegetal; áreas cobertas por rocha nua exposta.	
Área úmida	Área periodicamente inundada pelo transbordamento lateral do rio, lagoa, ou pelo afloramento de lençol freático.	
Agrocampestre	Área de campo com presença de árvores esparsas, tipicamente de savana, onde ocorrem as atividades agrícolas e pastagem de gado, com a presença de baixa densidade de residências de comunidades.	
Mangue	Formações florestais, densas, sempre-verdes, frequentemente inundadas pela maré e associadas ao ecossistema costeiro de Manguezal.	
Vegetação Densa	Estrutura florestal com cobertura arbórea espacial contínua.	

Fonte: Map Biomas (2018), IBGE (2013).

3.3. Classificação da cobertura da terra

A etapa de classificação supervisionada é o processo de rotular os objetos com base nas amostras de treinamento (Earthal *et al.*, 1991). Para isto, a tabela de atributos do arquivo vetorial (*shapefile*) gerado na segmentação, com os atributos extraídos das imagens e as amostras de treinamento, foi convertida para o formato CSV. A seguir, este arquivo foi inserido no ambiente [Google Collaboratory](#), para a realização dos testes de *machine learning*, a partir do uso da linguagem Python e da biblioteca *Scikit-learn*. As amostras foram divididas em duas partes: 30% para testes e 70% para treinamento.

Inicialmente, foi realizado um teste de desempenho, a partir do treinamento do algoritmo *Random Forest* (Breiman, 2001) com 1.000 árvores randômicas, avaliado com a métrica *F1-Score* para verificar o efeito do balanceamento de classes na performance pelo uso do algoritmo *RandomUnderSampler* da biblioteca *Scikit-learn*.

Após o teste inicial, foram utilizados quatro classificadores supervisionados de *machine learning* com bons resultados em sensoriamento remoto: *Random Forest* (Breiman, 2001; Belgiu e Dragut, 2016) e *Support Vector Classifier* (Mountrakis *et al.*, 2011), *eXtreme Gradient Boosting (XGBoost)* (Joharestani *et al.*, 2019; Bhagwat *et al.*, 2019) e *Multilayer Perceptron* (Saha *et al.*, 2021).

O classificador *Random Forest* baseia-se na metodologia de classificação por *ensemble learning* para criar de forma randômica várias árvores de decisão e combinar os múltiplos resultados para a decisão final, sendo altamente preciso (Breiman, 2001; Segal e Xiao, 2011). Além de apresentar bons resultados para a classificação de dados de sensoriamento remoto, fornece o grau de importância de cada atributo utilizado na classificação (Belgiu e Dragut, 2016).

O *Support Vector Classifier* (SVC) é um método de maximização de margens entre as amostras de treinamento de classes diversas (Faceli et al., 2021), em que os dados são separados no espaço de atributos a partir dos vetores de suporte que representam fronteiras de decisão (Faceli et al., 2021).

O *Multilayer perceptron* (MLP) faz uso de uma rede neural de múltiplas camadas baseado na técnica de aprendizado supervisionado, inspirado no cérebro humano, onde cada neurônio recebe sinais de entrada e processa os sinais de saída. Os neurônios são conectados entre si, e as conexões são avaliadas usando o coeficiente de pesos (Svozil et al., 1997).

O *XGBoost* é um algoritmo similar ao *Random Forest* que combina múltiplas árvores de decisão e faz uso do método *Gradient Boosting* (Scikit-Learn, 2022; Chen & Guestrin, 2016).

Foram feitos testes com diferentes configurações de hiperparâmetros a partir do código em Python, desenvolvido por Paiva e Pereira (2021) para a classificação de textos. Com a utilização de busca exaustiva em *grid*, que automatiza

o processo (algoritmo *GridSearchCV*), disponível na biblioteca *Scikit-Learn*, foi feita a seleção dos modelos com os melhores ajustes de hiperparâmetros para cada algoritmo utilizado (Tabela 3).

A avaliação dos modelos foi realizada pela métrica *F1 Score* (Equação 5), definida como a média harmônica entre a medida de Precisão (Equação 6) e de *Recall* (Equação 7), sendo 1 a pontuação máxima e 0 a mínima (Scikit-Learn, 2022).

$$F1\ Score = (2 * Precisão * Recall) / (Precisão + Recall) \quad (5)$$

$$Precisão = (VP + VN)/T \quad (6)$$

$$Recall = VP/(VP + FN) \quad (7)$$

em que: VP representa os verdadeiros positivos, VN os verdadeiros negativos, FN os falsos negativos e T o total de amostra

Correção da classificação e geração do ISL

Nesta etapa, foi aplicada a máscara de água, criada a partir das imagens SAR/Sentinel-1, para a remoção de polígonos referentes aos corpos de água na classificação da cobertura da terra. Foram editados pequenos polígonos de Área Descoberta referentes às áreas urbanas com base na interpretação visual das imagens do *Google Earth*. O mesmo procedimento foi adotado nas pequenas áreas úmidas e corpos de água. A seguir, feitas todas as correções, aplicou-se a máscara gerada com o MDE para delimitar as áreas situadas abaixo de 10 m e, assim, definir a zona costeira utilizada.

Tabela 3. Hiperparâmetros usados na busca exaustiva em *grid* (*GridSearchCV*).

RANDOM FOREST		MLP		SVC		XGBClassifier	
parâmetro	valor	parâmetro	valor	parâmetro	valor	parâmetro	valor
<i>max_depth</i> :	[5,7,9]	<i>activation</i> :	['identity', 'logistic', 'tanh', 'relu']	<i>gamma</i> :	['auto', 'scale']	<i>n_estimators</i> :	[100]
<i>min_samples_split</i> :	[2,3]	<i>solver</i> :	['lbfgs', 'sgd', 'relu']	<i>C</i> :	[0.5, 1]	<i>subsample</i> :	[.8,.45]
<i>min_samples_leaf</i> :	[1,2]	<i>alpha</i> :	[1]	<i>kernel</i> :	['linear', 'poly', 'rbf', 'sigmoid']	<i>learning_rate</i> :	[0.01]
<i>max_samples</i> :	[.8 1]	<i>max_iter</i> :	[1000]			<i>min_child_weight</i> :	[1]
<i>n_estimators</i> :	[100, 500, 1000]					<i>max_depth</i> :	[3,4,7]
						<i>random_state</i> :	[DEFAULT_RANDOM_STATE]
						<i>reg_lambda</i> :	[2]

No ambiente *QGIS*, o mapa da cobertura da terra foi reclassificado para as classes ISL, que variam 1 a 10, de acordo com a geomorfologia do litoral (Tabela 4), sendo que o menor valor corresponde à menor sensibilidade e vice-versa, seguindo as Especificações e Normas Técnicas para Elaboração de Cartas de Sensibilidade Ambiental para Derramamentos de Óleo da República Federativa do Brasil (Brasil, 2002).

4. RESULTADOS E DISCUSSÃO

4.1. Algoritmos de *machine learning*

Em relação ao teste inicial do efeito do balanceamento de classes no desempenho, o teste indicou valores semelhantes de *F1-Score* (~0.98) para o treinamento do *Random Forest* com e sem o balanceamento de classes. Por conta dos valores de *F1-Score* serem próximos e pelo fato de não haver grande desbalanceamento de amostras por classe de cobertura da terra (Figura 4), os demais testes foram executados com os dados sem o balanceamento de classes.

No teste realizado pela busca exaustiva em *grid* (*GridSearchCV*) com os quatro algoritmos de *machine learning*, não foi verificada diferença expressiva entre o desempenho (*F1-Score*) dos modelos selecionados com as melhores configurações de hiperparâmetros. Todos os modelos apresentaram valores de *F1-Score* maiores que 0.90: *Random Forest* - 0.97; *XGBClassifier* - 0.96; *SVC* - 0.95; e *MLP* - 0.92 (Figura 5).

No entanto, como o *Random Forest* obteve o maior valor de *F1-Score*, foi selecionado para a classificação da cobertura da terra com a melhor configuração de hiperparâmetros selecionados pela busca exaustiva em *grid* (Tabela 5). Tal fato é corroborado pela literatura de sensoriamento remoto, que indica o uso do *Random Forest* em dados com alta multicolinearidade e alta dimensionalidade, como as imagens de sensoriamento remoto (Belgiu e Dragut, 2016).

Além disso, Purwanto *et al.* (2022) descrevem que o *Random Forest* alcançou a acurácia de até 97% em estudo realizado na Indonésia em ambientes de manguezais, com a base de dados composta por bandas espectrais e índices de vegetação do Landsat, além do MDE. Especificamente sobre a costa oeste africana, Mondal *et al.* (2019) obtiveram acurácia de 93% com o *Random Forest* no mapeamento de manguezais em Gâmbia e Senegal, países vizinhos de Guiné-Bissau, no entanto com a base de dados formada por apenas bandas e índices de vegetação espectrais do Sentinel.

Tabela 4. Tipos de costas conforme o Índice de Sensibilidade ao Litoral (ISL).

ÍNDICE	TIPOS DE COSTA
SL 1	Costões rochosos lisos e expostos de alta declividade
	Falésias em rochas sedimentares expostas
	Estruturas artificiais lisas (paredões marítimos artificiais) expostas
ISL 2	Costões rochosos lisos, de declividade média a baixa, expostos
	Terraços ou substratos de declividade média expostos (terraço ou plataforma de abrasão, terraço arenítico exumado bem consolidado, etc.)
ISL 3	Praias dissipativas de areia média a fina, expostas
	Faixas arenosas contíguas à praia, não vegetadas, sujeitas à ação de galgamentos (restingas isoladas ou múltiplas, feixes alongados de restingas tipo "long beach")
	Escarpas e taludes íngremes (formações do grupo Barreiras e Tabuleiros Litorâneos) expostos
	Campos de dunas expostos
ISL 4	Praias de areia grossa
	Praias intermediárias de areia fina a média, expostas
	Praias de areia fina a média, abrigadas
ISL 5	Praias mistas de areia e cascalho, ou conchas e fragmentos de corais
	Terraço ou plataforma de abrasão de superfície irregular ou recoberta de vegetação
	Recifes areníticos em franja
ISL 6	Praias de cascalho (seixos e calhaus)
	Costa de detritos calcários
	Depósito de tálus
	Enrocamentos ("rip-rap", guia corrente, quebra-mar) expostos
	Plataforma ou terraço exumado recoberto por concreções lateríticas (disformes e porosas)
ISL 7	Planície de maré arenosa exposta
	Terraço de baixa-mar
ISL 8	Escarpa / encosta de rocha lisa, abrigada
	Escarpa / encosta de rocha não lisa, abrigada
	Escarpas e taludes íngremes de areia, abrigados
	Enrocamentos ("rip-rap" e outras estruturas artificiais não lisas) abrigados
ISL 9	Planície de maré arenosa / lamosa abrigada e outras áreas úmidas costeiras não vegetadas
	Terraço de baixa-mar lamoso abrigado
	Recifes areníticos servindo de suporte para colônias de corais
ISL 10	Deltas e barras de rio vegetadas
	Terraços alagadiços, banhados, brejos, margens de rios e lagoas
	Brejo salobro ou de água salgada, com vegetação adaptada ao meio salobro ou salgado; apicum
	Marismas
	Manguezal (mangues frontais e mangues de estuários)




Figura 4. Número de amostras por classe de cobertura da terra.




Figura 5. Avaliação dos modelos de machine learning testados.

Tabela 5. Hiperparâmetros usados na classificação pelo algoritmo *Random Forest*.

Hiperparâmetro	Valor
<i>max_depth</i>	9
<i>min_samples_split</i>	2
<i>min_samples_leaf</i>	1
<i>max_samples</i>	0.8
<i>n_estimators</i>	1000
<i>random_state</i>	42

Dos atributos utilizados para a classificação das imagens, a mediana (q50) de *MMRI* obteve o maior valor de importância relativa (0.0772), seguida dos outros cinco atributos mais importantes: mediana e média de *MMRI* (0.0769), mediana do MDE (0.0629), média da banda 4 (vermelho) (0.0555) e média de MDE (0.0553), como pode-se constatar na Figura 6.

O fato dos dois atributos mais importantes serem relativos ao *MMRI* é explicado pela grande extensão de manguezais na costa guineense (Diniz, 1994), evidenciando o potencial do índice na separação espectral entre essa vegetação e os demais alvos (Diniz,

et al., 2019), conforme pode ser visto na Figura 7 (a) e (b), que mostra a mediana e a média do *MMRI* do manguezal com valor menor, próximo a 1.0, do que dos demais alvos, com valores entre -0.5 a 0.5. A mediana do MDE foi considerado terceiro atributo importante na classificação, pois os manguezais e, também, as áreas úmidas e descobertas (apicuns) estão localizados nas áreas planas de menor elevação no litoral (menor 4 m) e próximos aos cursos de água que entram pelo interior (Figura 7c) (Diniz, 1994), o que é corroborado por Thomas *et al.* (2018) ao mencionarem a importância do uso do MDE no mapeamento de manguezais em escala global. Por fim, na banda 4, o manguezal junto com a vegetação densa possuem os menores valores de reflectância do que os demais alvos (Figura 7d), pois apresentam maior absorção da faixa de vermelho devido à fotossíntese.

4.2. Classificação da cobertura da terra

A classificação obtida para a cena em estudo a partir do algoritmo *Random Forest* está apresentada na Figura 8. A capital da Guiné-Bissau, Bissau, está aí localizada, correspondendo à região mais povoada do país e, assim, não apresenta somente a vulnerabilidade às mudanças climáticas, como afirma o estudo da Fandé *et al.*, (2020), mas também ao derramamento de óleo, que pode impactar diretamente o ambiente e as atividades econômicas.

A zona costeira, nesta cena, ou seja, com a altitude até 10 m, corresponde a 2925.6 km² e, segundo os resultados da classificação, as classes de cobertura da terra estão assim distribuídas: Área Úmida com 43%, Mangue com 20%, Agrocampo com 31%, Área Descoberta com 0.7%, e Vegetação Densa com 5%.

4.3. Índice de Sensibilidade do Litoral

Na classificação do ISL foram definidos os índices 3, 7, 8, 9 e 10 (Figura 9), os demais valores não foram identificados na região. Devido à limitação do nosso método, não foi medida a granulometria da areia das praias, um dos parâmetros utilizados para atribuir os índices nestas feições, porém como as praias aí presentes são dissipativas de areia média a fina, atribuiu-se o índice 3.

Os índices 8, 9 e 10 representam 94.4% da zona costeira da cena, considerados os locais mais difíceis para remover o óleo, devido à sua composição e dinâmica. A área de índice 8, abaixo da cota de 10 m, é ocupada por residências e comércios, localizados na área urbanizada da capital. A área de índice 9, na sua maioria, corresponde ao cultivo de arroz das comunidades tradicionais (ANEME, 2018), enquanto o índice 10 corresponde aos mangues e áreas úmidas, onde as comunidades tradicionais retiram os seus alimentos, além de ser considerado lugar de culto para muitas etnias (Rabelo *et al.*, 2018).




Figura 6. Importância relativa dos atributos na classificação por *Random Forest*.




Figura 7. Boxplot dos cinco atributos mais importantes (*Random Forest*).




Figura 8. Classificação da cobertura da terra do ano de 2020, faixa da zona costeira, Guiné-Bissau.




Figura 9: Índice de Sensibilidade do Litoral (ISL) ao Óleo, faixa da zona costeira, Guiné Bissau.

5. CONCLUSÕES

A classificação do ISL ao derrame de óleo de parte da zona costeira de Guiné-Bissau, com 94.4% da área de estudo apresentando índice acima de 8, mostra a importância de estudos e da adoção de medidas para a redução dos riscos de exposição ao óleo, ainda mais considerando que se localiza próxima da rota de petroleiros de países vizinhos produtores de petróleo. Os resultados obtidos para esta área podem ser extrapolados para o restante do litoral, pois apresentam feições geomorfológicas semelhantes à zona classificada.

Também deve ser enfatizado que a elevada amplitude da maré conjuntamente com a baixa declividade facilitam que a contaminação por óleo atinja distantes áreas no interior do continente, como no caso da zona estudada cuja presença de alto ISL ocorre até 95 km da linha de costa. Na ocorrência de eventos extremos, mais comuns com as alterações climáticas, a área atingida pode ser ampliada. No caso, por exemplo, de ocorrer uma estiagem severa, provocando a redução da vazão, o fluxo de maré pode atingir o leito dos canais de drenagem em áreas mais interiores.

Não menos relevante, é a importância da zona costeira para a sobrevivência das comunidades tradicionais, seja no fornecimento de alimentos e habitação, seja na sua importância cultural. Desta forma, enfatiza-se a importância da avaliação da vulnerabilidade socioambiental ao derramamento de óleo no litoral da Guiné-Bissau.

Desta forma, este trabalho, além de alertar sobre a vulnerabilidade da zona costeira guineense, contribui para o futuro detalhamento e extensão da classificação de ISL a todo o litoral guineense, bem como para a criação da Carta SAO.

Por fim, este trabalho também visa encorajar os pesquisadores a darem atenção ou a terem visão crítica face às atividades petrolíferas na Guiné-Bissau, já que os resultados aqui alcançados mostram o quanto a região apresenta elevada vulnerabilidade ao derramamento de óleo.

CONTRIBUIÇÕES

- Jairson Alberto Sami - jairsonalberto@id.uff.br - <https://orcid.org/0009-0009-7844-5783> Desenvolvimento da metodologia, coleta e análise dos dados, redação do artigo.
- Cristiane Nunes Francisco - cristianenf@id.uff.br - <https://orcid.org/0000-0002-8688-9810> - Concepção da pesquisa, revisão da análise dos dados, e orientadora do estudo.

- Pedro José Farias Fernandes - pj_fernandes@id.uff.br - <http://orcid.org/0000-0002-1862-2401> - Desenvolvimento da metodologia, revisão da análise dos dados, e coorientador do estudo.
- Tiago Fernando de Holanda - tiagofh@id.uff.br - <https://orcid.org/0000-0001-6898-5027> - Desenvolvimento da metodologia, revisão da análise dos dados.

Todos os autores contribuíram na revisão e edição do artigo, e aprovam a versão final do documento.

REFERÊNCIAS BIBLIOGRÁFICAS

- ANEME (2018). *Enquadramento perspectivas de desenvolvimento, levantamento e caracterização das empresas comerciais e industriais*. Associação Nacional das Empresas Metalúrgicas e Electromecânicas ANEME, Lisboa, Portugal. Disponível on-line em <https://www.aneme.pt/site/2018/07/03/estudo-guine-bissau/>
- Aps, R; Töniss, H.; Suursaar, U; Orvik, K. (2016). Regional environmental sensitivity index (RESI) classification of Estonian shoreline (Baltic Sea). *Journal of Coastal Research*, 75(1), 972-976. DOI: 10.2112/SI75-195.1
- Aragão, J.R.V.; Zuidema, P.A.; Groenendijk, P. (2021) Climate-growth relations of congeneric tree species vary across a tropical vegetation gradient in Brazil. *Dendrochronologia*. DOI: 10.1016/j.dendro.2021.125913
- Arvor, D.; Durieux, L.; Andrés, S.; Laporte, M. (2013). Advances in Geographic Object-Based Image Analysis with ontologies: A review of main contributions and limitations from a remote sensing perspective. *ISPRS Journal of Photogrammetry and Remote Sensing*, 82, 125-137. DOI: 10.1016/j.isprsjprs.2013.05.003
- Batz, M.; Schape, A. (2000). Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation. In: Strobl, J., Blaschke, T. and Griesbner, G., Eds., *Angewandte Geographische Informations-Verarbeitung*, XII, Wichmann Verlag, Karlsruhe, Germany, 12-23.
- Banco Mundial. (1992). *Avaliação hidrológica da África Sul-Saariana, Países da África d'Oeste*. Guiné-Bissau. Disponível on-line em https://horizon.documentation.ird.fr/exl-doc/pleins_textes/divers17-05/010004456.pdf
- Barry, A.A.; Caesar, J.; Tank, A.M.G.K.; Aguilar, E.; McSweeney, C.; Cyrille, A.M.; Nikiema, M.P.; Narcisse, K.B.; Sima, F.; Stafford, G. et al. (2018) West Africa climate extremes and climate change indices. *International Journal of Climatology*, v. 38, p. e921-e93. DOI: 10.1002/joc.5420
- Belgiu, M.; Dragut, L. (2016). Random forest in remote sensing: A review of applications and future directions. *ISPRS journal of photogrammetry and remote sensing*, v. 114, p. 24-31. DOI: 10.1016/j.isprsjprs.2016.01.011

- Beneditti, C.A.; Riedel, P.S.; Lupinacci, C. M.; Milanelli, J.C.C.; Aguilar, R. L. (2016). Mapeamento dos índices de sensibilidade ambiental ao óleo em trecho do Rio Tietê. *Geociências*, 35(2), 220-230, São Paulo, Brasil. Disponível on-line em <https://www.periodicos.rc.biblioteca.unesp.br/index.php/geociencias/article/view/11377>
- Benz, U. C.; Hofmann, P.; Willhauck, G.; Lingenfelder, I; Heynen, M. Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. *ISPRS Journal of photogrammetry and remote sensing*, v. 58, n. 3-4, p. 239-258. DOI: 10.1016/j.isprsjprs.2003.10.002
- Bhagwat, R.U.; Shankar, U.B. (2019). A novel multilabel classification of remote sensing images using XGBoost. In: *2019 IEEE 5th International Conference for Convergence in Technology (I2CT)*. IEEE. p. 1-5. DOI: 10.1109/I2CT45611.2019.9033768
- Brasil - Ministério do Meio Ambiente. (2002). *Especificações e normas técnicas para elaboração de cartas de sensibilidade ambiental para derramamentos de óleo. Ministério do Meio Ambiente, Brasília, Brasil*. Disponível on-line em http://www.iepa.ap.gov.br/saofza/pdf/anexoll_especificacoes_normas_tecnicas_elaboracao_cartas_sao.pdf
- Breiman, L. (2001) *Random Forests*. *Machine Learning* 45, 5–32. DOI: 10.1023/A:1010933404324
- Brubacher, J.P.; Guasselli, L.A.; Oliveira, G.G. (2017). Delimitação de áreas inundáveis a partir de Modified Normalized Difference Water Index (MNDWI) no Município de Esteio (RS, Brasil). *Pesquisas em Geociências*, 44(2), 367. Rio Grande Sul, Brasil. DOI: 10.22456/1807-9806.78279
- Chen, T.; Guestrin, C. (2016). *Xgboost: A scalable tree boosting system*. In: *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*. p. 785-794. DOI: 10.1145/2939672.2939785
- Ndehedehe, C.E.; Usman, M.; Okwuashi, O.; Ferreira, V.G. (2021). Modelling impacts of climate change on coastal West African rainfall. *Modeling Earth Systems and Environment*. DOI: 10.1007/s40808-021-01302-5
- Cremon, É.H.; Bettiol, G. M.; Júnior, J. P.M.; Macedo, F.C.; Rabelo, M.D.O. (2022). Avaliação da altimetria do MDE COP-30 no Centro-Oeste do Brasil. *Revista Brasileira de Cartografia*, 74(3). DOI: 10.14393/rbcv74n3-60846
- Diniz, C.; Cortinhas, L.; Nerino, G.; Rodrigues, J.; Sadeck, L.; Adami, M.; Souza-Filho, P.W.M. (2019). *Brazilian mangrove status: Three decades of satellite data analysis*. *Remote Sensing*, 11(7). DOI: 10.3390/rs11070808
- Diniz, M.A. (1994). Aspectos do mangal da Guiné-Bissau. *Anais do Instituto Superior de Agronomia*. Lisboa, Portugal. Disponível on-line em <https://www.repository.utl.pt/bitstream/10400.5/16126/1/REP-ANAIS-57-20093078445.pdf>
- Earthal, J. G.; Fonseca, L.M.G.; Bins, L.S.; Velasco, F.R.D.; Monteiro, A.M.V. (1991) *Um sistema de segmentação e classificação de imagens de satélite*. Inpe, São José dos Campos/SP, Brasil. Disponível on-line em <http://sibgrapi.sid.inpe.br/8JMKD3MGPBW34M/3CN624H?ibiurl.language=en>
- El Mahrad, B.; Mahrad, B.E.; Newton, A.; Icely, J. D.; Kacimi, I.; Abalansa, S.; Snoussi, M. (2020). Contribution of remote sensing technologies to a holistic coastal and marine environmental management framework: A review. *Remote Sensing*, 12(14). DOI: 10.3390/rs12142313
- Faceli, K., Lorena, A. C., Gama, J., Almeida, T. A. D., Carvalho, A. C. (2011). *Inteligência artificial: uma abordagem de aprendizado de máquina*. LTC, Rio de Janeiro, Brasil. ISBN: 9788521618805
- Fandé, M. B.; Ponte Lira, C.; Antunes, C.; Penha-Lopes, G. (2020). Quantificação e cartografia da extensão de inundação costeira em Bissau, Guiné-Bissau: perspectiva em cenário de alterações climáticas. *Comunicações Geológicas*. Lisboa, Portugal. Disponível on-line em <http://hdl.handle.net/10451/46297>
- Galieriková, A.; Materna, M. (2020). World seaborne trade with oil: One of main cause for oil spills? *Transportation Research Procedia*, 44, 297-304. DOI: 10.1016/j.trpro.2020.02.039
- Gonzalez, R.C; Woods, R.E. (2009). *Processamento digital de imagens*. Pearson Educación, São Paulo, Brasil. ISBN: 978-8576054016
- Gorelick, N.; Hancher, M.; Dixon, M.; Ilyushchenko, S.; Thau, D.; Moore, R. (2017) *Google Earth Engine: Planetary-scale geospatial analysis for everyone*. *Remote sensing of Environment*, v. 202, p. 18-27. DOI: 10.1016/j.rse.2017.06.031
- Graham, E.; Ovadia, J. S. (2019). Oil exploration and production in Sub-Saharan Africa, 1990-present: Trends and developments. *Extractive Industries and Society*, 6(2), 593-609. DOI: 10.1016/j.exis.2019.02.001
- Hänsch, R. (2020). Machine learning in remote sensing In: Chen, C.H. *Handbook of pattern recognition and computer vision*, 6th ed., pp. 187-207. World Scientific Publishing Company, EUA. DOI: 10.1142/9789811211072_0010
- Hayes, M.O.; Michel, J.; Brown, P.J. (1977). *Vulnerability of coastal environments of Lower Cook Inlet, Alaska to oil spill impact*. In: 4th International Conference on Port and Ocean Engineering under Arctic Conditions (POAC 77), Newfoundland Memorial University, Canada, September 26-30. <https://trid.trb.org/view/56990>
- Hijmans, R.J.; Van Etten, J.; Cheng, J.; Mattiuzzi, M.; Sumner, M.; Greenberg, J.A.; Lamigueiro, O.P.; Bevan, A.; Racine, E.B.; Shortridge, A. (2015). Package ‘raster’. R package, 734, p.473.
- INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. Manual técnico de uso da terra. *Manuais Técnicos em Geociências*, n. 7, 2013. Disponível on-line em Manual técnico de uso da terra - IBGE | PDF (slideshare.net)

- IBAP. Instituto de Biodiversidade e Áreas Protegidas. (2022). *Áreas protegidas*. Guiné-Bissau. In <https://ibapgbissau.org/areas-protegidas/>
- Jensen, J.R.; Halls, J.N.; Michel, J. (1998). A systems approach to environmental sensitivity index (ESI) mapping for oil spill contingency planning and response. *Photogrammetric Engineering and Remote Sensing*, 64(10), 1003-1014. Disponível on-line em https://www.asprs.org/wp-content/uploads/pers/1998journal/oct/1998_oct_1003-1014.pdf.
- Joharestani *et al.* (2019). PM2.5 prediction based on random forest, XGBoost, and deep learning using multisource remote sensing data. *Atmosphere*, v. 10, n. 7, p. 373. DOI: 10.3390/atmos10070373
- Map Biomas Legenda Coleção 7 - Descrição Detalhada, 2018. Disponível on-line em Legenda Coleção 7 - Descrição Detalhada | PDF | Pasto | Agricultura (scribd.com)
- Maretti, C.C. (2002). Planificação costeira da Guiné-Bissau; Princípios, procedimentos e resultados. *Jornal de Gerenciamento Costeiro Integrado UNIVALI*, 1-25, São Paulo, Brasil. Disponível on-line em https://www.researchgate.net/publication/271842008_Planificacao_Costeira_da_Guine-Bissau_Principios_Procedimentos_e_Resultados.
- Marinho, C.; Nicolodi, J.L.; Arigony-Neto, J. (2021). Vulnerabilidade ambiental a derramamentos de óleo no Parque Estadual de Itapua, Rio Grande do Sul, Brasil: Uma abordagem usando simulação numérica bidimensional. *Environmental Pollution*, 288(1). DOI: 10.1016/j.envpol.2021.117872
- Marinho, C.; Nicolodi, J.L. (2019). Integração de parâmetros geomorfológicos e biológicos no desenvolvimento do Índice Integrado de Sensibilidade do Litoral (IISL). *Revista Brasileira de Geografia Física*, v. 12 n. 4, 1509-1524. DOI: 10.26848/rbfg.v12.n4.p1509-1524
- Martins, P.T.A.; Riedel, P.S.; Milanelli, J.C.C. (2013). Carta de sensibilidade ambiental ao óleo: origem, evolução e tendências. *Ciência e Natureza*, 35(2), 163-175. DOI: 10.5902/2179460X12570
- Maxwell, A.E.; Warner, T.A.; Strager, M.P.; Conley, J.F.; Sharp, A.L. (2015). Assessing machine-learning algorithms and image-and lidar-derived variables for GEOBIA classification of mining and mine reclamation. *International Journal of Remote Sensing*, v. 36, n. 4, p. 954-978. DOI: 10.1080/01431161.2014.1001086
- McFeeters, S.K. (1996). The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. *International journal of remote sensing*, v. 17, n. 7, p. 1425-1432. DOI: 10.1080/01431169608948714
- Michel, J.; Hayes, M.O.; Brown, P.J. (1978). Application of an oil spill vulnerability index to the shoreline of lower Cook Inlet, Alaska. *Environment geology*, v. 2, p. 107-117. DOI: 10.1007/BF02380473
- Mondal, P.; Liu, X.; Fatoyinbo, T.E.; Lagomasino, D. (2019). Evaluating combinations of sentinel-2 data and machine-learning algorithms for mangrove mapping in West Africa. *Remote Sensing*, v. 11, n. 24, p. 2928. DOI: 10.3390/rs11242928
- Mountrakis, G.; Im, J.; Ogole, C. (2011). Support vector machines in remote sensing: A review. *ISPRS journal of photogrammetry and remote sensing*, v. 66, n. 3, p. 247-259. DOI: 10.1016/j.isprsjprs.2010.11.001
- Muler, M.; Romero, A.F.; Riedel, P.S.; Perinotto, R. R. C. (2011). Ações de Resposta para Emergência em caso de Derrames de Óleo no Mar e Proposta de Implementação de Sistema de Informação voltado à Sensibilidade Ambiental para o Litoral Sul Paulista, Brasil. *Revista de Gestão Costeira Integrada*, 11(4), 397-407. DOI: 10.5894/rgci250
- Nwilo, P.C.; Badejo, O.T. (2006). Impacts and Management of Oil Spill Pollution along the Nigerian Coastal Areas. *Administering Marine Spaces*, (119), 1-15. DOI: 10.4236/gep.2019.78024
- ONU. Organizações das Nações Unidas. (2022). *World Population Prospects 2024*. Disponível on-line em <https://population.un.org/wpp/Graphs/>
- Paiva, E; Pereira, F.S. (2021). Extraction and enrichment of features to improve complaint text classification performance. In: *Anais do XVIII Encontro Nacional de Inteligência Artificial e Computacional*. SBC. p. 338-349. DOI: 10.5753/eniac.2021.18265
- Pincinato, F. L.; Riedel, P.S.; Milanelli, J.C.C. (2009). Modelling an expert GIS system based on knowledge to evaluate oil spill environmental sensitivity. *Ocean and Coastal Management*, 52(9), 479-486. DOI: 10.1016/j.ocecoaman.2009.08.003
- Purwanto, A.D.; Wikantika, K.; Deliar, A.; Darmawan, S. (2022). Decision Tree and Random Forest Classification Algorithms for Mangrove Forest Mapping in Sembilang National Park, Indonesia. *Remote Sensing*, v. 15, n. 1, p. 16. DOI: 10.3390/rs15010016
- Rabelo, F.D.B.; Carvalho, R.G.; Silva, E.V.; Junior, A. C. (2018). Características das áreas protegidas em Guiné-Bissau: O caso do Parque Natural dos Tarrafes do Rio Cacheu. *Revista Eletrônica Casa de Makunaima*. DOI: 10.24979/makunaima.v1i2.461
- Rouse, J.W.; Haas, R.H.; Schell, J.A.; Deering, D.W. (1974) Monitoring vegetation systems in the Great Plains with ERTS. NASA Spec. Publ. v. 351, n. 1, p. 309. Disponível on-line em <https://ntrs.nasa.gov/api/citations/19740022614/downloads/19740022614.pdf>
- Saha, S.; Paul, G.C.; Pradhan, B.; Abdul Maulud, K.N.; Alamri, A.M. (2021). Integrating multilayer perceptron neural nets with hybrid ensemble classifiers for deforestation probability assessment in Eastern India. *Geomatics, Natural Hazards and Risk*, v. 12, n. 1, p. 29-62. DOI: 10.1080/19475705.2020.1860139
- Scikit-Learn (2022). *Machine Learning in Python*. Disponível on-line em <https://scikit-learn.org/stable>
- Segal, M.; Xiao, Y. (2011). Multivariate random forests. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 1(1), 80-87. DOI: 10.1002/widm.12
- Svozil, D.; Kvasnicka, V.; Pospichal, J. (1997). J. Introduction to multi-layer feed-forward neural networks. *Chemometrics and*

- Intelligent Laboratory Systems*, 39(1), 43–62. DOI: 10.1016/S0169-7439(97)00061-0
- Tabua de Maré (2022). *Tábua de maré com condições de mar na Guiné-Bissau 2022*. Disponível on-line em <https://tabuademares.com/gw/guinea-bissau/bissau>
- Thomas, N.; Bunting, P.; Lucas, R.; Hardy, A.; Rosenqvist, A.; Fatoyinbo, T. (2018). Mapping mangrove extent and change: A globally applicable approach. *Remote Sensing*, v. 10, n. 9, p. 1466. DOI: 10.3390/rs10091466
- Trimble (2022). *eCognition*. Version 9. software. Disponível on-line em <https://geospatial.trimble.com/en/products/software/trimble-ecognition>
- UNEP (2007). World Conservation Monitoring Centre. *Mangroves of Western and Central Africa. UNEP-Regional Seas Programme/ UNEP-WCMC*. Bissau, Guiné-Bissau. Disponível on-line em <https://aquadocs.org/handle/1834/5474>
- Viegas, S.V.; Miglhorance, E.W.; Almeida, P.M.M.; Cruz, C.B.M.; Souza, E.M.F.R; Soares, M.L.G; Estrada, G.C. (2019). *Análise da resposta espectral dos diferentes tipos de mangue: estudo de caso da Baía de Sepetiba*. In: Simpósio Brasileiro de Sensoriamento Remoto, 19. INPE, São José dos Campos/SP, Brasil. p. 3108-3111. ISBN 978-85-17-00097-3. Disponível on-line em <http://urlib.net/ibi/8JMKD3MGP6W34M/3U25BRL>
- Xie, G., & Niculescu, S. (2021). Mapping and monitoring of land cover/ land use (LCLU) changes in the crozon peninsula (Brittany, France) from 2007 to 2018 by *machine learning* algorithms (support vector machine, *random forest*, and convolutional neural network) and by post-classification comparison (PCC). *Remote Sensing*, 13(19), 3899. DOI: <https://doi.org/10.3390/rs13193899>
- Weather Spark (2022): *Clima e condições meteorológicas médias em Bissau no ano todo*. Disponível on-line em <https://pt.weatherspark.com/y/31647/Clima-caracter%C3%ADstico-em-Bissau-Guin%C3%A9-Bissau-durante-o-ano#Sections-Humidity>

