

Classificação supervisionada aprimorada para mapeamento da floresta de mangue a partir de imagens de satélite Landsat 8

Oldim Lodes A. Chuquelane Vilanculo^{1*}, Kátia Monica Bouene², Helder Arlindo Machaieie³

¹Graduado em Geologia Marinha, Universidade Eduardo Mondlane, Moçambique. (*Autor correspondente: ochuquelane@gmail.com)

²Graduada em Biologia Marinha, Universidade Eduardo Mondlane, Moçambique.

³Doutor em Dinâmica dos Oceanos e da Terra, Universidade Eduardo Mondlane, Moçambique.

Histórico do Artigo: Submetido em: 09/09/2024 – Revisado em: 24/12/2024 – Aceito em: 02/03/2025

RESUMO

O monitoramento das florestas de manguezais é essencial para uma compreensão mais aprofundada do cenário ecológico e da necessidade de conservação desses ecossistemas. Utilizando imagens de satélite de acesso livre, como as do sensor Landsat 8, esta pesquisa buscou mapear a extensão das florestas de manguezais em uma resolução de 30 metros no estuário do rio Macuse localizado no centro de Moçambique. O diferencial deste estudo está no uso de diferentes índices espectrais, como o NDVI, NDWI e o mais recente índice de vegetação de manguezais, o MVI (Mangrove Vegetation Index). Essa abordagem possibilitou através da classificação supervisionada random forest, a separação eficiente da vegetação de manguezais em relação a outras classes de cobertura do solo, alcançando uma precisão notável de 95%, conforme indicado pelo coeficiente kappa.

Palavras-Chaves: Índice de Vegetação de Mangal (MVI), Google Earth Engine, Random Forest.

Enhanced Supervised Classification for Mangrove Forests Mapping Using Landsat 8 Satellite

ABSTRACT

Monitoring mangrove forests is essential for a deeper understanding of the ecological scenario and the need for conservation of these ecosystems. Using freely accessible satellite images, such as those from the Landsat 8 sensor, this research aimed to map the extent of mangrove forests at a 30-meter resolution in the Macuse River estuary, located in central Mozambique. The distinguishing factor of this study lies in the use of different spectral indices, such as NDVI, NDWI, and the most recent Mangrove Vegetation Index (MVI). This approach enabled the efficient separation of mangrove vegetation from other land cover classes through Random forest algorithm for supervised classification, achieving a remarkable accuracy of 95%, as indicated by the kappa coefficient.

Keywords: Mangrove Vegetation Index (MVI), Google Earth Engine, Random Forest.

Clasificación Supervisada Mejorada para el Mapeo de Bosques de Manglares con el Satélite Landsat 8

RESUMEN

El monitoreo de los bosques de manglares es esencial para una comprensión más profunda del escenario ecológico y la necesidad de conservación de estos ecosistemas. Utilizando imágenes satelitales de libre acceso, como las del sensor Landsat 8, esta investigación tuvo como objetivo mapear la extensión de los bosques de manglares con una resolución de 30 metros en el estuario del río Macuse, ubicado en el centro de Mozambique. El factor distintivo de este estudio radica en el uso de diferentes índices espectrales, como NDVI, NDWI y el más reciente Índice de Vegetación de Manglares (MVI). Este enfoque permitió la separación eficiente de la vegetación de manglares de otras clases de cobertura terrestre a través del algoritmo de bosque aleatorio para la clasificación supervisada, logrando una notable precisión del 95%, como lo indica el coeficiente kappa.

Palabras clave: Índice de Vegetación de Manglares (MVI), Google Earth Engine, Bosque aleatorio.

Vilanculo, O. L. A. C., Bouene, K. M., Machaieie, H. A. (2025). Classificação supervisionada aprimorada para mapeamento da floresta de mangue a partir de imagens de satélite Landsat 8. *Revista Brasileira de Sensoriamento Remoto*, v.6, n.1, p.14-24.



1. Introdução

O mapeamento de florestas de mangais utilizando dados de sensoriamento remoto continua a ser um desafio por diversos motivos, apesar dos avanços tecnológicos. Um dos principais obstáculos é a confusão espectral entre os mangais e outras vegetações com assinaturas espectrais semelhantes, o que dificulta a distinção precisa através dos métodos tradicionais de sensoriamento remoto.

No entanto, nas últimas décadas, o desenvolvimento de algoritmos avançados de classificação e a disponibilidade de aplicativos de processamento de imagem facilitaram o mapeamento em larga escala de florestas de mangais (Bunting et al., 2018; Fatoyinbo e Simard, 2011; Moxon, 2021). Em Moçambique, dados de sensoriamento remoto integrados a Sistemas de Informação Geográfica (SIG) têm sido amplamente utilizados para estimar a cobertura de mangais (Barbosa et al., 2001; Shapiro, 2018). De acordo com a FAO (2005), a cobertura de mangais em Moçambique era de 396.080 hectares em 1999. Fatoyinbo e Simard (2013) observaram uma redução dessa área para 305.400 hectares, e Shapiro (2018) estimou uma cobertura total de 225.995 hectares em 2016. Esses estudos, baseados em metodologias de sensoriamento remoto, evidenciam a contínua redução da extensão de mangais no país.

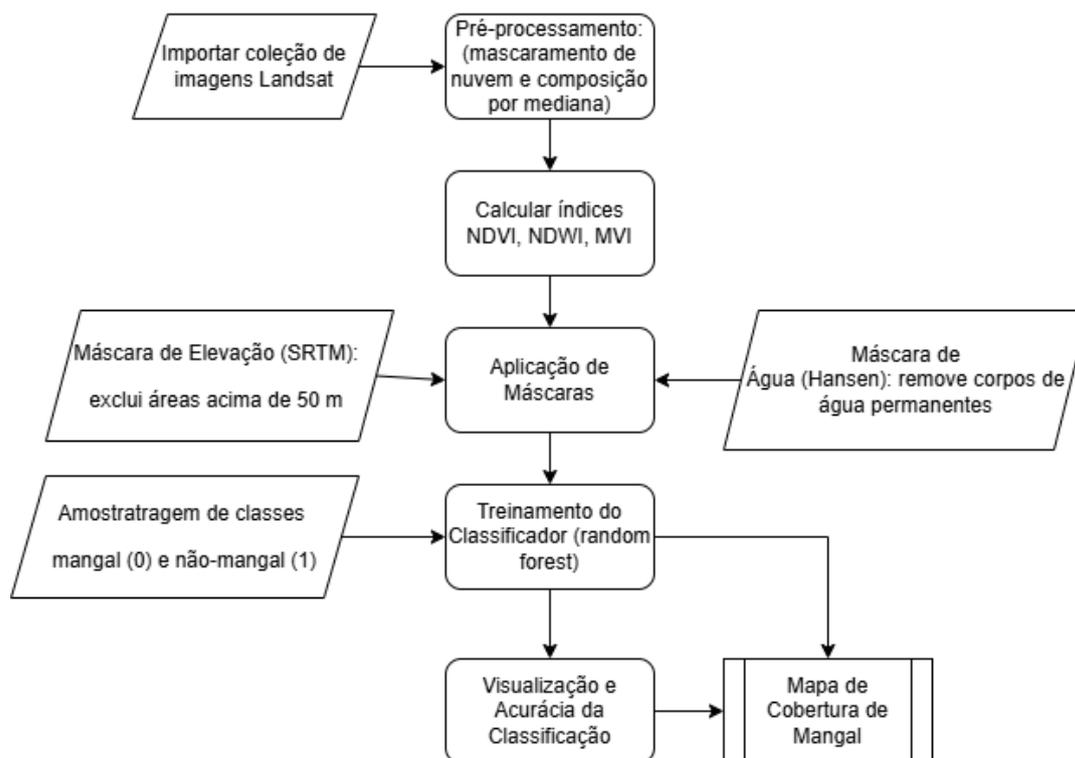
Para facilitar a detecção de florestas de mangais, índices espectrais como NDVI, EVI e SAVI são comumente utilizados (Tran et al., 2022). No entanto, esses índices, quando utilizados isoladamente, apresentam limitações na discriminação precisa dessa vegetação. A integração desses índices espectrais, de modo a resumir informações de múltiplas bandas espectrais, é a abordagem proposta nesta pesquisa. Estudos indicam que abordagens de classificação híbrida, que combinam índices espectrais, alcançam maior precisão em comparação com métodos que utilizam apenas dados espectrais brutos (Pesaresi et al., 2024).

Embora imagens de satélite, como as obtidas pelos sensores Landsat e Sentinel, sejam amplamente utilizadas para a análise de mangais em softwares especializados (como o ArcGIS), o mapeamento em larga escala enfrenta limitações relacionadas ao tempo de processamento, à disponibilidade de dados e ao volume necessário. Para superar essas restrições, esta pesquisa propõe o uso da plataforma Google Earth Engine, aliada a uma classificação aprimorada que integra diversos índices espectrais. O Google Earth Engine tem sido amplamente utilizado para extração de florestas de mangais em grande escala devido à sua capacidade de processamento de dados em nuvem (Chen et al., 2017). A plataforma oferece uma variedade de conjuntos de dados de acesso livre e atualizados continuamente, permitindo aos usuários integrarem grandes volumes de dados geoespaciais para o mapeamento histórico e o monitoramento de mudanças (Gorelick et al., 2017).

2. Material e Métodos

O fluxo geral do processo desta pesquisa é apresentado na Figura 1. A etapa inicial consistiu na criação de uma composição a partir da coleção de imagens Landsat 8, definindo a variável temporal. Foram selecionadas seis imagens, filtradas por data (de 01 de janeiro a 31 de dezembro de 2021), da coleção 2, nível 1, correspondentes a imagens de reflectância de superfície corrigidas atmosféricamente, derivadas dos dados produzidos pelos sensores Landsat 8 OLI/TIRS.

Figura 1 - Fluxograma da metodologia aplicado no Google Earth Engine
 Figure 1 - Flowchart of the methodology applied in Google Earth Engine.



A plataforma do Google Earth Engine fornece uma variedade de conjuntos de dados constantemente atualizados que podem ser acessados diretamente no editor de código. Assim sendo, para este estudo não foi necessário fazer o download de imagens brutas no *Earth Explorer* (earthexplorer.usgs.gov).

2.1. Procedimentos no Google Earth Engine

O conjunto de dados Landsat 8 ("LANDSAT/LC08/C02/T1_L2") contém imagens de refletância de superfície corrigidas atmosféricamente. Essas imagens incluem cinco bandas no espectro do infravermelho próximo e visível (VNIR) e duas bandas no infravermelho de ondas curtas (SWIR). Esses dados são de domínio público e podem ser utilizados, transferidos ou reproduzidos sem restrições de direitos autorais. O conjunto de dados Landsat 8 pode ser explorado e analisado utilizando o Editor de Código em Javascript, disponível no Google Earth Engine.

2.2. Determinação de Índices Espectrais

Os índices espectrais foram calculados para destacar pixels em uma imagem e mostrar a abundância relativa de uma cobertura de terra de interesse. Para destacar a cobertura vegetal foi calculado o Índice de Vegetação por Diferença Normalizada (NDVI) de Rouse et al., (1974):

$$NDVI = \frac{\text{Banda 5} - \text{Banda 4}}{\text{Banda 5} + \text{Banda 4}} \quad (1)$$

Para destacar os corpos de água, foi calculado o Índice de água de diferença normalizada (NDWI). Os valores de limiar NDWI maiores que 0 visualizam corpos de água da superfície (McFeeters, 2016):

$$NDWI = \frac{Banda\ 3 - Banda\ 5}{Banda\ 3 + Banda\ 5} \quad (2)$$

Para destacar os ecossistemas de mangal foi calculado o Índice de Vegetação de Mangal (MVI) de Baloloy et al., (2020). Esse novo índice simplificado permite o mapeamento rápido e preciso da extensão de mangal a partir de imagens de satélite. A equação do Índice de Vegetação de Mangal (MVI) está na forma:

$$MVI = \frac{Banda\ 5 - Banda\ 3}{Banda\ 6 - Banda\ 3} \quad (3)$$

Onde: **Banda 3 - Verde**: 0.53 – 0.59 μm (resolução de 30m); **Banda 4 - Vermelho**: 0.64 – 0.67 μm (resolução de 30m); **Banda 5 - Infravermelho Próximo (NIR)**: 0.85 – 0.88 μm (resolução de 30m); **Banda 6 - Infravermelho de Curto Comprimento de Onda (SWIR 1)**: 1.57 – 1.65 μm (resolução de 30m).

2.3. Classificação supervisionada das imagens Landsat-8

O comando Classifier do Google Earth Engine é projetado para realizar classificações supervisionadas utilizando algoritmos tradicionais de Machine Learning, como CART (Classification and Regression Trees) e Random Forest. A natureza interativa da plataforma Earth Engine permite o desenvolvimento iterativo de fluxos de trabalho para classificação supervisionada, integrando diferentes conjuntos de dados no modelo. Este módulo cobre etapas essenciais, como o fluxo de trabalho básico de classificação supervisionada, avaliação de precisão e detecção de mudanças.

Neste trabalho, utilizou-se o algoritmo Random Forest, amplamente aplicado em estudos que empregam bandas espectrais para a classificação de espécies de mangal. O Random Forest é uma ferramenta de Machine Learning baseada em algoritmos de inteligência artificial, reconhecida por sua eficiência computacional e alta precisão. Estudos anteriores destacaram seu desempenho superior em relação a outros algoritmos supervisionados no mapeamento de vegetação de mangal (Shapiro, 2018; Toosi et al., 2019; Moxon, 2021). O fluxo de trabalho geral para classificação supervisionada no Google Earth Engine envolveu as seguintes etapas:

(1) Pré-processamento

A seleção das imagens Landsat 8 foi feita usando o filtro por data e cobertura de nuvens. As imagens selecionadas são combinadas para reduzir a variabilidade atmosférica, e a coleção é reduzida para uma imagem média (*collection_reduce*), representando uma síntese temporal de todo o período selecionado. As florestas de mangal podem apresentar alterações espectrais devido a mudanças sazonais, o que pode influenciar os valores espectrais e complicar a comparação temporal das imagens capturas por Satélites.

A composição de imagens no Google Earth Engine, pode mitigar esses efeitos pois permite a combinação de múltiplas imagens capturadas em um intervalo de tempo em uma única imagem composta de características predominantes, reduzindo o impacto das mudanças sazonais e condições climáticas, como cobertura de nuvens e mudanças no nível da água. O Mascaramento de Nuvens foi feita através da função *maskL8sr*. Esta função, aplica uma máscara de nuvens aos dados do satélite Landsat 8 (L8) para garantir que a análise seja feita apenas em pixels sem cobertura de nuvens ou com saturação radiométrica.

(2) Cálculo de Índices Espectrais

Com as imagens preparadas, determinou-se o NDVI combinando as bandas do infravermelho próximo (NIR) e do vermelho, ajudando a identificar áreas com alta vegetação. O NDWI combinando as bandas verde e infravermelho de onda curta (SWIR). E o MVI, usando as bandas de NIR, verde e SWIR (infravermelho de onda curta). O código a seguir calcula três índices espectrais importantes para o mapeamento de mangais:

```
//Função dos índices
function indices (image) {
  //Índices de Vegetação. (Rouse, 1973)
  var ndvi = image.normalizedDifference(['SR_B5',
'SR_B4']).rename('NDVI');
  // Índices de Vegetação de Mangal. (Baloloy et al.,2020)
  var mvi = image.expression(
    '(NIR - GREEN)/(SWIR - GREEN)', {
      'NIR': image.select('SR_B5'),
      'GREEN': image.select('SR_B3'),
      'SWIR': image.select('SR_B6')
    }).rename('MVI');
  //Índices de Água. (Mc Feeters, 1996)
  var ndwi = image.normalizedDifference(['SR_B3',
'SR_B5']).rename('NDWI');
  return image.addBands([ndvi,mvi,ndwi])
}
```

(3) Aplicação de máscara de elevação e de água

A floresta de mangal geralmente cresce em áreas costeiras de baixa elevação, próximas ao nível do mar (Chen et al., 2017). Portanto, excluir regiões acima de 50 metros ajuda a limitar a análise às áreas onde os mangais são ecologicamente possíveis. O processo de Máscara de Elevação utiliza dados do modelo de elevação SRTM (*Shuttle Radar Topography Mission*) para excluir áreas acima de 50 metros. Para isso, uma máscara foi criada a partir da banda de elevação (elevation), mantendo apenas os pixels com valores inferiores a 50 m. Essa máscara é então aplicada à coleção reduzida, resultando em uma imagem que inclui apenas regiões de baixa elevação, onde os mangais são ecologicamente viáveis.

A máscara de água foi usada para garantir que a análise inclua apenas regiões que estão em terra firme, próximas a corpos de água, ou em zonas intertidais. Utilizou-se a coleção da máscara de água produzida por Hansen et al. (2013) que representa água persistente ao longo de 2000–2012. Apenas pixels classificados como "terra firme" foram mantidos na análise, garantindo que corpos de água permanentes sejam excluídos. Combinando as duas máscaras (elevação e água), as imagens foram refinadas para a área de interesse, focando exclusivamente nas zonas terrestres costeiras de baixa altitude, adequadas para o crescimento de mangais.

(4) Coleta de dados de treinamento

O objetivo dessa etapa foi identificar as classes dos alvos e armazenar em valores numéricos a assinatura espectral em rótulo de classe conhecido para os preditores. As amostras de treinamento foram criadas interativamente usando as ferramentas de desenho (ferramenta polígono e marcadores) disponíveis na plataforma do Google Earth Engine (GEE), onde os locais de treinamento foram selecionados a partir de uma inspeção visual do basemap do GEE.

(5) Geração de amostras de treinamento

Quando as amostras de treinamento são desenhadas, novas classes são criadas automaticamente. No Google Earth Engine, os dados de treinamento foram armazenados como “*FeatureCollection*” (figura 2), com uma propriedade que armazena o rótulo da classe e propriedades que armazenam variáveis de previsão. Para esta etapa, foram geradas amostras de treinamento para cada classe (tabela 1). As coleta amostras de pixels da imagem foram classificadas: mangais e não-Mangais, limitados a 1000 pixels por classe. Essas amostras, foram combinadas em um único conjunto e receberam uma coluna de valor aleatório para separação em treinamento (70%) e teste (30%).

Tabela 1 - Definição dos dados dados de treinamento

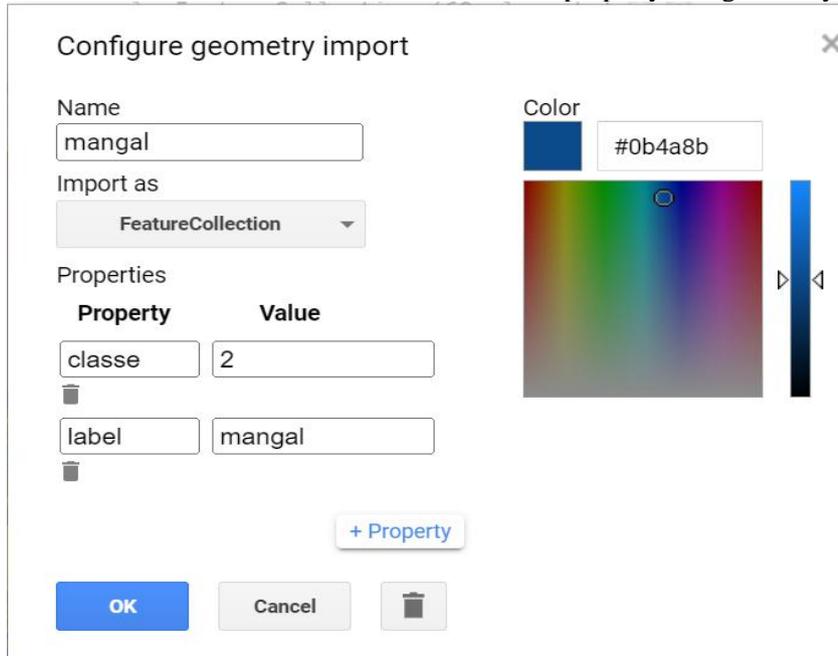
Table 1 – Defining training data.

<i>Cobertura do Terrestre</i>	<i>Valor da Classe</i>	<i>Rotulo/ Label</i>
Área de cobertura por Mangal	0	mangal
Área sem cobertura por Mangal	1	naomangal

Os rótulos de classe devem ser consecutivos, inteiros começando de 0 até mais infinito. Para esse caso, foram definidos números 0 e 1. Essas amostras são coletadas a partir das áreas definidas como “mangal” e “naomangal”, extraídas usando as regiões de interesse (ROI).

Figura 2 - Definição de cada coleção de feição para uma propriedade reconhecida pelo algoritmo

Figure 2 - Definition of each feature collection for a property recognized by the algorithm.



(6) Aplicação da classificação

A configuração do algoritmo Random Forest foi realizada definindo o número de árvores como 500, garantindo robustez e precisão na classificação. O modelo foi treinado utilizando amostras de treinamento previamente coletadas, onde as variáveis de entrada foram as bandas espectrais e os índices de vegetação (NDVI, NDWI e MVI), e as classes de saída foram "mangal" (0) e "não-mangal" (1). O processo de treinamento foi conduzido pelo método *train*, que construiu as árvores de decisão a partir das amostras, permitindo ao modelo aprender as características espectrais de cada classe. Após o treinamento, o classificador foi aplicado à imagem para prever as classes de todos os pixels, utilizando o método *classify*.

(7) Avaliação de precisão

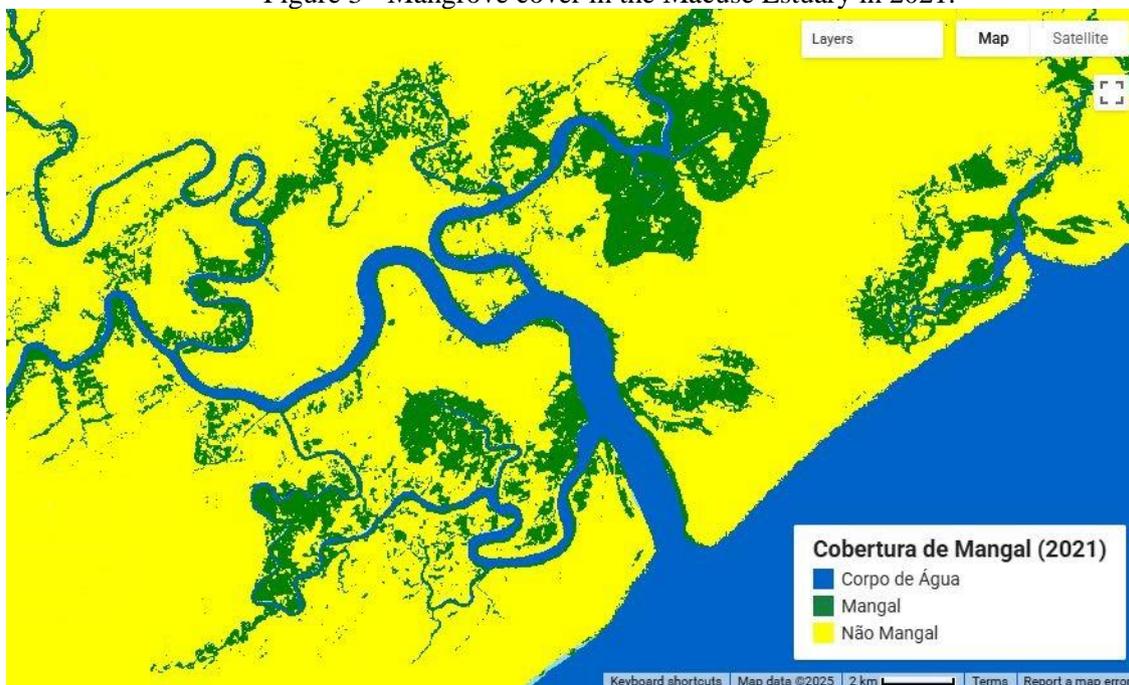
Para a avaliação da precisão do classificador, foi extraída a matriz de confusão que representam a precisão do treinamento e da validação. Como referência para dados de validação usou-se a imagem do Basemap do Google, disponível no GEE. A acurácia do classificador foi realizada com base nas amostras de teste, gerando uma matriz de confusão que apresenta o desempenho da classificação. Métricas como Acurácia Geral, Acurácia do Consumidor e do Produtor, além do Índice Kappa, são calculadas para validar a precisão do classificador e sua capacidade de diferenciar as classes de interesse.

3. Resultados

A imagem classificada é visualizada no mapa utilizando uma paleta de cores que diferencia as classes: verde para "mangais" e amarelo para "não-mangais" (figura 3).

Figura 3 - Cobertura da floresta de mangal no Estuário Macuse em 2021.

Figure 3 - Mangrove cover in the Macuse Estuary in 2021.



Essa visualização permite identificar espacialmente as áreas classificadas. A área classificada como "não-mangal" inclui zonas dominadas por solo exposto, habitações, estradas e vegetação, como árvores e outras plantas, com ou sem estrutura acima do solo. Contudo, não abrange corpos de água. A classe de corpo de água no mapa é representativa, extraída do mapa global de uso e cobertura terrestre com resolução de 10 metros para o ano de 2021, *WorldCover* da Agência Espacial Europeia (ESA). A classe "não-mangal" representa, portanto, todas as coberturas terrestres não associadas diretamente ao ecossistema de mangais. No estudo em questão, a área mapeada de mangal corresponde a 8281.4 hectares.

Os resultados da avaliação estatística destacam a alta precisão da classificação realizada. A matriz de confusão apresenta os seguintes valores: 52 pixels classificados corretamente como "mangal" e 295 como "não-mangal", com apenas 2 pixels erroneamente classificados como "não-mangal". A acurácia geral é de 99,4%, refletindo a confiabilidade do modelo. A acurácia do consumidor é de 96,3% para "mangal" e 100% para "não-mangal", enquanto a acurácia do produtor é de 100% para "mangal" e 99,3% para "não-mangal". O índice Kappa, que mede a concordância além do acaso, foi de 0,98, indicando uma classificação extremamente consistente e precisa.

Tabela 2 - Matriz de confusão da imagem classificada
Table 3 - Confusion matrix of the classified image.

		Dados da Validação			Precisão do Produtor
		Mangal	Não mangal	Total	
Dados da classificação	Mangal	52	0	52	1
	Não mangal	2	295	297	0.99
	Total	54	295	349	
	Precisão do usuário	0.96	1		
Acurácia geral = 0.99			Kappa = 0.98		

A combinação de verdades de campo e pontos de validação selecionados aleatoriamente, resultam num coeficiente kappa de 0,98 para avaliação geral. Em termos práticos, significa que 98% dos erros potenciais de uma classificação aleatória foram evitados. Essa alta precisão demonstra que o modelo de classificação está representando de forma confiável as categorias de interesse (mangal e não-mangal) com base nos dados utilizados.

4. Discussão

A utilização de múltiplos índices espectrais, como NDVI, NDWI e o MVI, proposto por Baloloy et al. (2020), demonstrou-se fundamental para melhorar a precisão no mapeamento das florestas de mangais em 2021, atingindo uma precisão do usuário de 96% e do produtor de 100%. Isso reflete uma abordagem altamente eficaz em comparação a um estudo realizado na mesma região por Furaca et al. (2021), que, no mapeamento das uso e cobertura terrestre do Estuário dos Bons Sinais, alcançaram uma precisão do usuário de 81% e do produtor de 91% para a vegetação de mangal. A discrepância de 19 pixels classificados incorretamente como "mangal", está, possivelmente, relacionado a mistura espectral em pixels com cobertura mista. Este erro de omissão para a vegetação de mangal pode ocorrer devido ao uso de classificação supervisionada baseada nas em espectrais (vermelho, verde, azul e infravermelho próximo), que não conseguem distinguir adequadamente

entre vegetação de mangal e outras coberturas como vegetação herbácea de áreas úmidas, resultando em classificações menos precisas.

O presente estudo resolve a problemática de mistura espectral, propondo a combinação de índices espectrais como o NDVI, o NDWI e o MVI, que utilizam informações de bandas adicionais, como o infravermelho próximo (NIR) e o infravermelho de ondas curtas (SWIR). Essas bandas são altamente sensíveis à saúde da vegetação, à umidade do solo e à presença de corpos de água (Rouse et al., 1974; McFeeters, 2016), permitindo uma discriminação mais precisa entre diferentes classes, como mangais, pastagens, vegetação herbácea de áreas úmidas. Além disso, o classificador de Máxima Verossimilhança (MLC) aplicado no estudo de Furaca et al. (2021) assume distribuições normais nas amostras de treinamento, o que nem sempre é verdadeiro para dados de imagens de satélite, podendo levar a erros de classificação em algumas classes. Em alternativa, neste estudo, utilizou-se o classificador *Random Forest* para discriminar a vegetação de mangal das diferentes classes de cobertura do solo, por não assumir distribuições normais nos dados, levando em consideração as distribuições complexas das imagens de satélite devido à mistura espectral e heterogeneidade das paisagens. No estudo comparativo de diferentes algoritmos de classificação para monitoramento de mudanças na cobertura de mangais de Toosi et al. (2019), o algoritmo Random Forest (RF) teve o melhor desempenho.

Embora o MVI tenha sido projetado especificamente para identificar e mapear florestas de mangais, a aplicação de múltiplos índices espectrais (como MVI, NDVI e NDWI) em conjunto se justifica pela necessidade de capturar diferentes aspectos biofísicos e ambientais da paisagem, aumentando a precisão e a robustez do mapeamento. Os autores Neri et al. (2021) verificaram uma classificação incorreta do MVI em áreas de aquicultura, terras agrícolas irrigadas e locais com palmeiras, onde os pixels de mangais e vegetação circundante apresentam assinaturas espectrais altamente semelhantes.

Gupta et al. (2018) desenvolveram um índice aprimorado que integra informações do Índice de Vegetação por Diferença Normalizada (NDVI) e do Índice de Água por Diferença Normalizada (NDWI). Segundo esses autores, os ecossistemas de mangal apresentam alto teor de água em suas folhas, o que permite que prosperem em condições de alta salinidade. Assim, a combinação do NDWI e do NDVI, designada como Índice Combinado de Reconhecimento de Mangal, produziu uma precisão geral de classificação muito elevada. Portanto, a combinação desses índices (NDVI e NDWI), juntamente com o MVI (*Mangrove Vegetation Index*) no presente estudo, não apenas maximizou a separação espectral entre os mangais e outras classes de cobertura do solo, mas também possibilitou uma análise mais detalhada de suas condições ecológicas, demonstrando a eficácia dessa abordagem no mapeamento de florestas de mangais com alta precisão. Essa análise confirma a adequação do método utilizado, garantindo que os resultados podem ser aplicados com confiança para decisões de gestão e conservação dos mangais.

5. Conclusão

O uso combinado dos índices espectrais nomeadamente: MVI para destacar a floresta de mangal, NDVI para destacar a vegetação circundante não-mangal, NDWI para destacar os copos de água forneceu informação adicional ao algoritmo o que permitiu um a avaliação de precisão excelente.

Os resultados demonstraram a robustez da metodologia aplicada, evidenciada por uma precisão geral de 99% na classificação das áreas de mangal e um coeficiente kappa de 0,98, indicando uma confiabilidade significativa do processo de classificação. Além disso, a combinação dos diferentes índices espectrais, que capturam tanto a vegetação quanto o teor de água das folhas de mangal, mostrou-se eficiente, reforçando a eficácia de abordagens integradas para o mapeamento de ecossistemas complexos como o de mangais.

A alta precisão alcançada, tanto do ponto de vista do produtor (100%) quanto do usuário (96%), confirma que os métodos empregados são confiáveis e adequados para a detecção e monitoramento de mangais em larga escala. A precisão obtida na detecção de mangais pode ser utilizada para avaliar a saúde ecológica do

ecossistema, identificando áreas de degradação ou deterioração da vegetação que precisam de intervenção.

Estudos futuros podem explorar a aplicação de técnicas similares em outras áreas costeiras de Moçambique, ampliando o conhecimento sobre a extensão e o estado de conservação dos mangais em nível nacional. Dessa forma, será possível reforçar a importância desses ecossistemas e garantir sua preservação diante das ameaças globais e locais, como a urbanização e as mudanças climáticas.

6. Referências

- Baloloy, A. B., Blanco, A. C., Sta. Ana, R. R. C., Nadaoka, K. (2020). Development and application of a new mangrove vegetation index (MVI) for rapid and accurate mangrove mapping. *ISPRS Journal of Photogrammetry and Remote Sensing*, 166, 95–117. <https://doi:10.1016/j.isprsjprs.2020.06.001>
- Barbosa, F. M.A., C. C. Cuambe, and S. O. Bandeira. 2001. “Status and Distribution of Mangroves in Mozambique.” *South African Journal of Botany* 67 (3): 393–98;
- Bunting P., Rosenqvist A., Lucas R., Rebelo L-M., Hilarides L., Thomas N., Hardy A., Itoh T., Shimada M. and Finlayson C.M. (2018). The Global Mangrove Watch – a New 2010 Global Baseline of Mangrove Extent. *Remote Sensing* 10(10): 1669. <https://doi:10.3390/rs1010669>.
- Chen, B., Xiao, X., Li, X., Pan, L., Doughty, R., Ma, J., ... & Giri, C. (2017). A mangrove forest map of China in 2015: Analysis of time series Landsat 7/8 and Sentinel-1A imagery in Google Earth Engine cloud computing platform. *ISPRS Journal of Photogrammetry and Remote Sensing*, 131, 104-120.
- FAO (2005). “Global Forest Resources Assessment 2005: Thematic Study on Mangroves. Mozambique Country Profile.” Rome: Forest Resources Development Service, Forest Resources Division Forestry, Forestry Department. Food and Agriculture Organization of the United Nations.
- Fatoyinbo, T.E., Simard, M., 2013. Height and biomass of mangroves in Africa from ICESat/GLAS and SRTM. *Int. J. Remote Sens.* 34, 668–681.
- Furaca, N. B., Hogueane, A. M., Mackay, F., Willemsse, M., eLanga, A. A. (2021). Exploring urbanization and critical habitat loss through land cover change around the Bons Sinais Estuary, Mozambique. *Western Indian Ocean Journal of Marine Science*, (1/2021), 43-58.
- 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*, 202, 18-27.
- Gupta, K.; Mukhopadhyay, A.; Giri, S.; Chanda, A.; Majumdar, S.D.; Samanta, S.; Mitra, D.; Samal, R.N.; Pattnaik, A.K.; Hazra, S. (2018). An Index for Discrimination of Mangroves from Non-Mangroves Using LANDSAT 8 OLI Imagery. *MethodsX*, 5, 1129–1139.
- Hansen, M.C.; Potapov, P.V.; Moore, R.; Hancher, M.; Turubanova, S.A.; Tyukavina, A.; Thau, D.; Stehman, S.V.; Goetz, S.J.; Loveland, T.R. (2013). High-Resolution Global Maps of 21st-Century Forest Cover Change. *Science*.
- Mcfeters, 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.

- Moxon, Sayana de gorostizaga (2021). *Mapping mangrove forests: processing and visualization of multi-sensor earth observation data for the Colombian pacific coast*. PhD Thesis. Palacký University Olomouc.
- Neri, M. P., Baloloy, A. B., & Blanco, A. C. (2021). Limitation assessment and workflow refinement of the Mangrove Vegetation Index (MVI)-based mapping methodology using Sentinel-2 imagery. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 46, 235-242.
- Pesaresi, S., Mancini, A., Quattrini, G., & Casavecchia, S. (2024). Evaluation and Selection of Multi-Spectral Indices to Classify Vegetation Using Multivariate Functional Principal Component Analysis. *Remote Sensing*, 16(7), 1224.
- Rouse, J.W., Haas, R.H., Schell, J.A., & Deering, D.W. (1974). Monitoring vegetation systems in the great plains with ERTS. In: *Proceedings of the First Earth Resources Technology Satellite-1 Symposium*, Vol. I, Section A, pp. 309-317. NASA SP-351.
- Shapiro, Aurélie. 2018. “Mozambique Mangrove Extent 1995-Present.” Berlin, Germany: WWF Germany. <https://doi.org/10.13140/RG.2.2.18470.55367>.
- Toosi, N. B., Soffianian, A. R., Fakheran, S., Pourmanafi, S., Ginzler, C., & Waser, L. T. (2019). Comparing different classification algorithms for monitoring mangrove cover changes in southern Iran. *Global Ecology and Conservation*, 19, e00662.
- Tran, Thuong V., Ruth Reef, and Xuan Zhu. (2022). A Review of Spectral Indices for Mangrove Remote Sensing. *Remote Sensing* 14, no. 19: 4868. <https://doi.org/10.3390/rs14194868>

RESUMO GRÁFICO // GRAPHICAL ABSCTRACT

