



**UNIVERSIDADE EDUARDO MONDLANE**

FACULDADE DE CIÊNCIAS

DEPARTAMENTO DE MATEMÁTICA E INFORMÁTICA

PROGRAMA DE PÓS-GRADUAÇÃO EM SISTEMAS DE INFORMAÇÃO

GEOGRÁFICA PARA O DESENVOLVIMENTO SUSTENTÁVEL

**DISSERTAÇÃO DE MESTRADO**

**APLICAÇÃO DA DETECÇÃO REMOTA E DOS SISTEMAS  
DE INFORMAÇÃO GEOGRÁFICA PARA A ANÁLISE DA  
VARIAÇÃO TEMPORAL DO USO E COBERTURA DO SOLO  
NA BACIA HIDROGRÁFICA DO RIO UMBELUZI, 2019-2024**

**IUSSUFO MOMADE ANIFO ADADE**

Maputo

Fevereiro, 2025

**UNIVERSIDADE EDUARDO MONDLANE**  
FACULDADE DE CIÊNCIAS  
DEPARTAMENTO DE MATEMÁTICA E INFORMÁTICA  
PROGRAMA DE PÓS-GRADUAÇÃO EM SISTEMAS DE INFORMAÇÃO  
GEOGRÁFICA PARA O DESENVOLVIMENTO SUSTENTÁVEL

**DISSERTAÇÃO DE MESTRADO**

**APLICAÇÃO DA DETECÇÃO REMOTA E DOS SISTEMAS  
DE INFORMAÇÃO GEOGRÁFICA PARA A ANÁLISE DA  
VARIAÇÃO TEMPORAL DO USO E COBERTURA DO SOLO  
NA BACIA HIDROGRÁFICA DO RIO UMBELUZI, 2019-2024**

**IUSSUFO MOMADE ANIFO ADADE**

Dissertação de mestrado apresentado ao Programa de Pós-Graduação em Sistemas de Informação Geográfica para o Desenvolvimento Sustentável da Universidade Eduardo Mondlane, como parte dos requisitos para a obtenção do grau de Mestre em Sistemas de Informação Geográfica para o Desenvolvimento Sustentável.

Supervisora: Doutora Sheyla Ratan Rodrigues Cassy  
Co-supervisora: Mestre Susana Cardoso Paisana

Maputo

Fevereiro, 2025

**UNIVERSIDADE EDUARDO MONDLANE**  
FACULDADE DE CIÊNCIAS  
DEPARTAMENTO DE MATEMÁTICA E INFORMÁTICA  
PROGRAMA DE PÓS-GRADUAÇÃO EM SISTEMAS DE INFORMAÇÃO  
GEOGRÁFICA PARA O DESENVOLVIMENTO SUSTENTÁVEL

**APLICAÇÃO DA DETECÇÃO REMOTA E DOS SISTEMAS  
DE INFORMAÇÃO GEOGRÁFICA PARA A ANÁLISE DA  
VARIAÇÃO TEMPORAL DO USO E COBERTURA DO SOLO  
NA BACIA HIDROGRÁFICA DO RIO UMBELUZI, 2019-2024**

**IUSSUFO MOMADE ANIFO ADADE**

Dissertação de mestrado apresentado ao Programa de Pós-Graduação em Sistemas de Informação Geográfica para o Desenvolvimento Sustentável da Universidade Eduardo Mondlane, como parte dos requisitos para a obtenção do grau de Mestre em Sistemas de Informação Geográfica para o Desenvolvimento Sustentável.

Aprovado em \_\_\_\_ de \_\_\_\_\_ de 2025, por:

---

Doutor. Silvino Pedro Cumbane  
(Arguente - DMI-UEM)

---

Prof. Doutor. Ernesto Lenathy Muheca  
(Presidente - DMI-UEM)

---

Doutora. Sheyla Ratan Rodrigues Cassy  
(Supervisora – DMI-UEM)

---

Mestre. Susana Cardoso Paisana  
(Co-Supervisora – Consultec, Consultores Associados)

Maputo

Fevereiro, 2025

## **Declaração de Compromisso**

Declaro por minha honra que, este trabalho, nunca foi apresentado para a obtenção de qualquer grau ou num outro âmbito e que ele constitui o resultado do meu labor.

Todas as fontes usadas para este trabalho foram citadas e constam na lista de referências.

Este trabalho é apresentado em cumprimento parcial, dos requisitos para obtenção do grau de Mestrado em Sistemas de Informação Geográfica para o Desenvolvimento Sustentável, da Universidade Eduardo Mondlane.

---

Maputo, Fevereiro de 2025

Dedico este trabalho aos meus pais,

Romana Adamo Americano e Momade Anifo Adade.

## **AGRADECIMENTOS**

Em primeiro a Deus por me ter dado saúde e conhecimento.

A minha família que sempre me incentivou e me ajudou a superar vários desafios.

A minha orientadora Doutora Sheyla Cassy pelo apoio e disponibilidade para a orientação.

A Consultec Consultores Associados LDA, em especial ao Tiago Dray, a Susana Paisana, ao Miguel Nazareth e a Julieta Jetimane, por todo apoio prestado e pela disponibilidade e colaboração.

Aos meus colegas e companheiros do curso, pelo apoio mútuo, troca de conhecimento e ideias durante esta caminhada.

Aos professores do curso, pelo conhecimento transmitido e pelo aprendizado que me ajudou a crescer profissionalmente.

A todos que directa ou indirectamente contribuíram para a realização deste trabalho, a minha sincera gratidão!

## RESUMO

As mudanças do estado do uso e cobertura do solo nas bacias hidrográficas estão entre os principais impulsionadores das alterações ambientais globais em muitos países em desenvolvimento. Em Moçambique e Eswatini, as mudanças do uso e cobertura do solo causam sérios desafios à gestão dos recursos naturais nas bacias hidrográficas, especialmente na bacia do rio Umbeluzi, cuja gestão é compartilhada pelos dois países. Estes desafios ocorrem na forma de esgotamento dos recursos hídricos, conflitos de uso da terra e também são um factor determinante das mudanças climáticas. A detecção remota (DR) e Sistemas de Informação Geográfica (SIG) são ferramentas eficazes e frequentemente usadas para a compreensão abrangente da dinâmica das alterações no uso e cobertura do solo. O objectivo deste estudo foi aplicar técnicas de DR e SIG para analisar as variações das mudanças do uso e cobertura do solo na bacia hidrográfica do rio Umbeluzi entre os anos 2019 e 2024. Para tal, usou-se imagens de satélite Sentinel-2 para realizar a classificação supervisionada na plataforma do *Google Earth Engine*. A classificação supervisionada foi realizada com base no algoritmo de aprendizagem de máquina Floresta Aleatória (RF) e a avaliação da precisão dessa classificação foi feita através da matriz de confusão. O mapeamento e a análise da evolução do uso e cobertura do solo foram realizados com base no *software* ArcGIS Pro 3.2. Os resultados mostraram mudanças no uso e cobertura do solo da bacia do rio Umbeluzi durante o período em estudo. A classe construções urbanas reduziu em 8%, solo exposto ou pastagem aumentou em 16.7%, os corpos de água aumentaram em 77.4%, a vegetação perene ou bosques reduziu em 8.1%, a vegetação arbustiva reduziu em 12%, a área agrícola irrigada reduziu em 30.8%, o mangal aumentou em 5.6%, a agricultura de pequena escala aumentou em 4.6%.

A precisão da classificação alcançou valores consistentes acima de 0.8 para os índices gerados através da matriz de confusão. As conclusões deste estudo têm o potencial de contribuir significativamente para a gestão eficaz da bacia do rio Umbeluzi, proporcionando uma análise apropriada do potencial e da procura dos recursos hídricos, integrando tanto as necessidades das actividades humanas, com as actividades de sustentabilidade ecológica dos habitats aquáticos e ribeirinhos.

**Palavras-chaves:** Detecção remota, SIG, bacia do rio Umbeluzi, uso e cobertura do solo, detecção de mudanças.

## ABSTRACT

Land use and land cover changes in river basins are among the main drivers of global environmental change in many developing countries. In Mozambique and Eswatini, land use and land cover changes cause serious challenges to natural resource management in river basins, especially in the Umbeluzi River basin, which is jointly managed by both countries. These challenges occur in the form of water resource depletion, land use conflicts and are also a key driver of climate change. Remote sensing and Geographic Information Systems (GIS) are effective and frequently used tools for comprehensively understanding the dynamics of land use and land cover changes. The aim of this study was to use remote sensing and GIS techniques to analyse variations in land use and land cover changes in the Umbeluzi River basin for the years 2019 and 2024. For this purpose, satellite images from Sentinel-2 were used, on the Google Earth Engine platform, to compute supervised classification. Supervised classification was performed using machine learning Random Forest (RF) algorithm and the accuracy of the classification was evaluated using confusion matrix. Image processing and mapping were performed based on the ArcGIS Pro 3.2 software. The results showed changes in land use and land cover of the Umbeluzi River basin during the study period. The urban construction decreased by 8%; bare soil or pasture increased by 16.7%; water bodies increased by 77.4%; evergreen vegetation or woodlands decreased by 8.1%; shrublands decreased by 12%; irrigated agricultural area decreased by 30.8%; mangroves increased by 5.6%; small-scale agriculture increased by 4.6%. Classification accuracy consistently achieved values above 0.8 for the indices generated through the confusion matrix. The results of this study have the potential to contribute significantly to the effective management of the Umbeluzi River basin, providing an appropriate analysis of the potential and demand for water resources, integrating the needs of human activities with the ecological sustainability activities of aquatic and riparian habitats.

**Keywords:** Remot Sensing, GIS, Umbeluzi river basin, land use and land cover, change detection.

## ÍNDICE

<b>AGRADECIMENTOS .....</b>	<b>3</b>
<b>RESUMO .....</b>	<b>4</b>
<b>ABSTRACT .....</b>	<b>5</b>
<b>LIATA DE FIGURAS .....</b>	<b>8</b>
<b>LISTA DE TABELAS .....</b>	<b>9</b>
<b>ABREVIATURAS E ACRÓNIMOS.....</b>	<b>10</b>
<b>1. INTRODUÇÃO .....</b>	<b>11</b>
1.1. Enquadramento.....	11
1.2. Problema.....	12
1.3. Justificação .....	13
1.4. Relevância .....	13
1.5. Objectivos.....	14
1.5.1. Objectivo Geral.....	14
1.5.2. Objectivos Específicos.....	14
1.6. Estrutura do trabalho .....	14
<b>2. REVISÃO DA LITERATURA.....</b>	<b>15</b>
2.1. Uso e cobertura do solo.....	15
2.2. Detecção Remota.....	15
2.3. Sistemas de Informação Geográfica.....	20
2.4. Detecção Remota e Sistemas de Informação Geográfica.....	22
2.5. Pré-processamento de imagem.....	22
2.6. Classificação de imagens de detecção remota.....	22
2.5.2. Classificação não supervisionada .....	23
2.5.1. Classificação supervisionada.....	23
2.7. Algoritmos de aprendizagem de máquina para classificação de imagens de DR.....	24
2.8. Detecção de mudanças .....	27

2.9. Avaliação da precisão da classificação de imagens .....	28
<b>3. MATERIAL E MÉTODOS .....</b>	<b>31</b>
3.1. Descrição da Área de Estudo .....	31
3.2. Dados.....	32
3.3. Softwares utilizados .....	33
3.4. Métodos.....	34
3.4.1. Delimitação da bacia hidrográfica.....	34
3.4.2. Classificação do uso e cobertura do solo.....	35
3.4.3. Classificação supervisionada.....	36
3.4.4. Classes de uso e cobertura do solo .....	37
3.4.5. Amostras de treino.....	38
3.4.6. Detecção de mudanças.....	41
3.4.7. Avaliação da precisão e validação dos resultados .....	41
<b>3. RESULTADOS E DISCUSSÃO .....</b>	<b>42</b>
4.2. Detecção de mudanças .....	44
4.3. Validação dos resultados.....	48
<b>5. CONCLUSÕES E RECOMENDAÇÕES .....</b>	<b>55</b>
5.1. Conclusões .....	55
5.2. Limitações e Recomendações do estudo.....	56
<b>REFERÊNCIAS BIBLIOGRÁFICAS.....</b>	<b>57</b>

## LIATA DE FIGURAS

<b>Figura 1:</b> Componentes de um sistema de detecção remota.....	17
<b>Figura 2:</b> Faixa do espectro electromagnético visível aos seres humanos. ....	19
<b>Figura 3:</b> Modelo de dados e matricial (raster).....	21
<b>Figura 4:</b> Processo de classificação de imagem em detecção remota.....	24
<b>Figura 5:</b> Árvore de decisão para classificação do UCS através do RF. ....	25
<b>Figura 6:</b> Expansão da área urbana na foz do rio Umbeluzi entre os anos 2002 (esquerda) e 2022 (direita).....	28
<b>Figura 7:</b> Localização geográfica da bacia hidrográfica do rio Umbeluzi. ....	32
<b>Figura 8:</b> Diagrama de Processos para delimitação de uma bacia hidrográfica no ArcGIS Pro. ....	35
<b>Figura 9:</b> Delimitação da bacia hidrográfica do rio Umbeluzi e rede de drenagem. ....	35
<b>Figura 10:</b> Fluxograma do processo metodológico. ....	36
<b>Figura 11:</b> Mapa da distribuição espacial das mostras de treino para 2019. ....	40
<b>Figura 12:</b> Mapa da distribuição espacial das mostras de treino para 2024. ....	40
<b>Figura 13:</b> Distribuição espacial do uso e cobertura do solo da bacia do rio Umbeluzi para o ano de 2019. ....	42
<b>Figura 14:</b> Distribuição espacial do uso e cobertura do solo na bacia do rio Umbeluzi para o ano de 2024. ....	43
<b>Figura 15:</b> Mudanças do uso e cobertura do solo da bacia hidrográfica do rio Umbeluzi entre os anos 2019 e 2024.....	45
<b>Figura 16:</b> Mapas com ganhos e perdas da cobertura vegetal na bacia hidrográfica do rio Umbeluzi entre os anos 2019 e 2024. ....	47

## LISTA DE TABELAS

<b>Tabela 1:</b> Classificação dos valores do coeficiente Kappa. ....	30
<b>Tabela 2:</b> Bandas do Sentinel-2 e suas características. ....	33
<b>Tabela 3:</b> Esquema de classificação do uso e cobertura do solo da bacia do rio Umbeluzi. ...	37
<b>Tabela 4:</b> Número de amostras de treino por classe. ....	39
<b>Tabela 5:</b> Variação de classes de uso e cobertura do solo na bacia hidrográfica do rio Umbeluzi entre os anos de 2019 e 2024. ....	44
<b>Tabela 6:</b> Matriz de confusão da classificação do uso e cobertura do solo da imagem de 2019 com o algoritmo RF. ....	49
<b>Tabela 7:</b> Matriz de confusão da classificação do uso e cobertura do solo da imagem de 2024 com o algoritmo RF. ....	50
<b>Tabela 8:</b> Erro de omissão e erro de comissão da classificação do uso e cobertura do solo com o algoritmo RF. ....	50
<b>Tabela 9:</b> Matriz de confusão da classificação do uso e cobertura do solo da imagem de 2019 com o algoritmo CART. ....	50
<b>Tabela 10:</b> Matriz de confusão da classificação do uso e cobertura do solo da imagem de 2024 com o algoritmo CART. ....	51
<b>Tabela 11:</b> Erro de omissão e erro de comissão da classificação do uso e cobertura do solo com o algoritmo CART. ....	51
<b>Tabela 12:</b> Matriz de confusão da classificação do uso e cobertura do solo da imagem de 2019 com o algoritmo NB.....	51
<b>Tabela 13:</b> Matriz de confusão da classificação do uso e cobertura do solo da imagem de 2024 com o algoritmo NB.....	52
<b>Tabela 14:</b> Erro de omissão e erro de comissão da classificação do uso e cobertura do solo com o algoritmo NB.....	52

## ABREVIATURAS E ACRÓNIMOS

API	Interface de Programação de Aplicações
ARA-SUL	Administração Regional de Águas do Sul
CART	Árvores de Classificação e Regressão
CENACARTA	Centro Nacional de Cartografia e Teledeteção
DR	Detecção Remota
ESA	Agência Espacial Europeia
ESRI	<i>Environmental Systems Research Institute, Inc</i>
GEE	<i>Google Earth Engine</i>
IFN	Inventário Florestal Nacional
ICAT	Projecto de Transparência para Acção Climática em Eswatini
NASA	Administração Nacional da Aeronáutica e do Espaço dos Estados Unidos da América
NB	<i>Naive Bayes</i>
NIR	Infravermelho próximo
MDE	Modelo Digital de Elevação
RF	Floresta Aleatória
REM	Radiação Electromagnética
SIG	Sistemas de Informação Geográfica
STRM	<i>Shuttle Radar Topographic Mission</i>
UCS	Uso e Cobertura do Solo
USGS	<i>United States Geological Survey</i>

## 1. INTRODUÇÃO

### 1.1. Enquadramento

A bacia hidrográfica do rio Umbeluzi, compartilhada entre Moçambique e Eswatini, desempenha um papel crucial no abastecimento de água, agricultura e biodiversidade dos dois países. As bacias hidrográficas internacionais são bacias transfronteiriças, compartilhadas entre dois ou mais países e são um fenómeno comum no mundo. A gestão da bacia do rio Umbeluzi é feita individualmente por Moçambique e Eswatini, cada um com prioridades distintas (ARA-SUL, 2014; Karimi *et al.*, 2019).

A presente tese enquadra-se no âmbito de um estágio profissional integrado num projecto de actualização do "Estudo Conjunto da Bacia do Rio Umbeluzi de 2005", com foco na gestão integrada dos recursos hídricos entre Moçambique e Eswatini, através da elaboração de anexos para o Acordo do Curso de Água do Umbeluzi. A colaboração entre os dois países é fundamental para garantir a alocação eficiente e sustentável da água, o que se reflecte nas acções delineadas para a actualização da gestão dos recursos hídricos.

A avaliação da evolução do uso e cobertura do solo (UCS) é essencial no contexto da gestão integrada dos recursos hídricos disponíveis pois permite uma compreensão abrangente dos impactos das actividades humanas e naturais na dinâmica dos recursos hídricos, além de fornecer dados cruciais para a tomada de decisões informadas (Zhang *et al.*, 2017; Ghaffari *et al.*, 2010).

O uso de tecnologias como a detecção remota (DR) e o Sistema de Informação Geográfica (SIG) têm um papel fundamental na análise detalhada da evolução do UCS. Essas tecnologias permitem uma abordagem quantitativa, espacialmente detalhada e temporalmente precisa, facilitando o monitoramento das mudanças na paisagem e a gestão dos recursos naturais.

A DR, particularmente através de imagens de satélite, permite a colecta de dados sobre a cobertura do solo em escalas espaciais e temporais muito maiores do que seria possível utilizando métodos tradicionais de levantamento de campo (Jensen, 2015). Com isso, é possível monitorar e quantificar as mudanças na cobertura da terra ao longo do tempo, seja para identificar a expansão de áreas agrícolas, o desmatamento ou a urbanização, por exemplo. O uso combinado do SIG facilita a análise espacial dessas mudanças, permitindo

correlacionar os dados de cobertura com variáveis socioeconómicas, climáticas e ambientais (Skidmore, 2002).

A análise da evolução do uso do solo permite igualmente antecipar mudanças nos padrões de consumo e demanda de água. Com a ajuda de tecnologias como a DR e o SIG, é possível mapear a expansão de áreas irrigadas ou urbanas e projectar os impactos dessas mudanças nas necessidades futuras de água. Isso fornece uma base sólida para o planeamento de alocação de recursos hídricos, levando em consideração o crescimento populacional, as necessidades agrícolas e industriais, e os requisitos ecológicos de caudal dos rios.

Este trabalho descreve algumas actividades desenvolvidas ao longo do estágio, mas que evoluíram de forma independente, do desenvolvimento e progresso do projecto principal. O foco principal do estudo foi a aplicação de técnicas de classificação supervisionada e detecção de mudanças nas classes de UCS na bacia hidrográfica do rio Umbeluzi, entre os anos de 2019 e 2024. Essas actividades envolveram a análise e interpretação de imagens de satélite, visando identificar e quantificar as transformações na paisagem ao longo desse período.

## **1.2. Problema**

Moçambique e Eswatini enfrentam uma carência significativa de dados actualizados sobre o UCS, o que compromete a caracterização integrada e precisa da bacia hidrográfica do rio Umbeluzi. Em Moçambique, os dados mais recentes disponíveis provêm do Inventário Florestal Nacional (IFN) de Magalhães, de 2017, e do IFN de Marzole, de 2007. Em Eswatini, o projecto ICAT gerou mapas do UCS para os anos de 1990, 1995, 2000, 2010, 2015 e 2020. A ausência de dados actualizados do UCS dificulta a realização de uma avaliação abrangente da bacia, essencial para a gestão integrada dos recursos hídricos, a protecção ambiental e o desenvolvimento socioeconómico da região. Essa lacuna de informações impede a identificação detalhada das principais actividades humanas realizadas na bacia, seus locais de ocorrência e os impactos ambientais e sociais gerados pela gestão inadequada do uso do solo.

### **1.3. Justificação**

A realização deste estudo justifica-se pela necessidade de se obter dados actualizados e precisos do UCS na bacia hidrográfica do rio Umbeluzi, uma região compartilhada entre Moçambique e Eswatini, onde a gestão integrada dos recursos hídricos é crucial para a sustentabilidade ambiental e o desenvolvimento socioeconómico. Embora a bacia seja uma importante fonte de recursos hídricos para ambos países, a falta de informações actualizadas do UCS representa um obstáculo significativo para a caracterização abrangente da região, essencial para a formulação de políticas de gestão dos recursos naturais e o planeamento sustentável do uso do solo.

Neste contexto, o uso de ferramentas avançadas de DR e SIG surge como uma solução eficaz para superar a falta de dados actualizados, sem a necessidade de realizar levantamento de campo. Essas tecnologias permitem a análise e monitoramento das mudanças no UCS de forma eficiente e precisa.

### **1.4. Relevância**

A bacia do rio Umbeluzi é de extrema importância para Moçambique e Eswatini, pois, desempenha um papel crucial no abastecimento de água para o consumo doméstico, industrial e produção agrícola. Devido a sua natureza transfronteiriça, a caracterização do UCS em toda extensão da bacia é de extrema relevância para uma gestão integrada entre os dois países. Além disso, a caracterização e a análise da evolução de padrões do UCS permitem que sejam tomadas decisões informadas no processo de gestão da bacia.

O presente estudo oferece a oportunidade de aplicar técnicas de DR e SIG, na revisão e actualização de dados do UCS através de imagens de satélite e algoritmos de aprendizagem de máquina para a classificação supervisionada no *Google Earth Engine* (GEE). Técnicas de DR e SIG também serão aplicadas para analisar mudanças no UCS durante o período em estudo, na qual o resultado contribuirá para a investigação das causas dessas mudanças.

## **1.5. Objectivos**

### **1.5.1. Objectivo Geral**

Analisar a variação de padrões de classes do uso e cobertura do solo da bacia hidrográfica do rio Umbeluzi entre os anos 2019 e 2024.

### **1.5.2. Objectivos Específicos**

- Definir classes de uso e cobertura do solo na área de estudo;
- Realizar a classificação supervisionada do uso e cobertura do solo da bacia hidrográfica do rio Umbeluzi no GEE para os anos 2019 e 2024;
- Quantificar áreas ocupadas por cada classe do uso e cobertura do solo;
- Quantificar mudanças do uso e cobertura do solo;
- Produzir mapas do uso e cobertura do solo e de mudanças da cobertura vegetal predominante na bacia;

## **1.6. Estrutura do trabalho**

O presente trabalho encontra-se organizado em 5 capítulos. No capítulo 1 é feita a descrição da parte introdutória, a contextualização do trabalho, descrição do problema de pesquisa, justificação e a relevância do estudo e os objectivos. No capítulo 2 apresenta-se a pesquisa bibliográfica sobre a temática da DR e de SIG e do uso e cobertura do solo. Neste capítulo, são revistos alguns algoritmos de classificação supervisionada e detecção de mudanças comumente aplicados em estudos do UCS. O capítulo 3 descreve a área de estudo e os dados usados, bem como, a metodologia aplicada ao estudo de caso, os métodos usados para alcançar os objectivos propostos. No capítulo 4 apresenta-se os resultados do estudo e faz-se a discussão dos mesmos. E por último, o capítulo 5 apresenta as conclusões gerais que foram obtidas deste estudo e algumas recomendações e limitações do estudo.

## **2. REVISÃO DA LITERATURA**

### **2.1. Uso e cobertura do solo**

Os termos “uso do solo” e “cobertura do solo” têm sido muito utilizados como conceitos similares, no entanto, existe uma distinção entre eles. O termo cobertura do solo refere-se ao tipo de feição presente à superfície da terra, enquanto, o termo uso do solo refere-se à actividade humana ou função económica associada a uma área específica da superfície terrestre (Meyer e Turner, 1994). Portanto, a cobertura do solo reflecte o tipo de paisagem presente numa determinada área, isto é, se é uma área de cobertura florestal, solo exposto, corpos de água, construções, etc. Já o uso do solo refere-se à finalidade socioeconómica dessas áreas, isto é, se é uma área residencial, área de conservação, produção agrícola, produção florestal, indústria, comércio, infra-estrutura e serviços, etc.

O uso dos termos juntos como UCS ocorre geralmente no contexto dos mapas UCS (Campbell e Wynne, 2011). Esses mapas contêm informações espaciais sobre a cobertura ou uso do solo e, geralmente, contêm classes que distinguem elementos como estruturas artificiais, agricultura, elementos e água. Estudos do UCS fornecem uma visão clara sobre como a terra está a ser utilizada e desempenham um papel crucial em diversos contextos, como ferramenta fundamental para o planeamento e a gestão sustentável dos recursos naturais (Anderson *et al.*, 1976). A análise detalhada do UCS através de séries temporais de imagens de satélite (ou mapas de UCS) é importante no processo de tomada de decisões a nível da administração local e nacional, pois, fornece informações valiosas para construir estratégias de gestão dos recursos naturais e das mudanças ambientais, bem como crescimento urbano (Treitz *et al.*, 2004; Rogan e Chen, 2004).

### **2.2. Detecção Remota**

#### **2.2.1. Conceito**

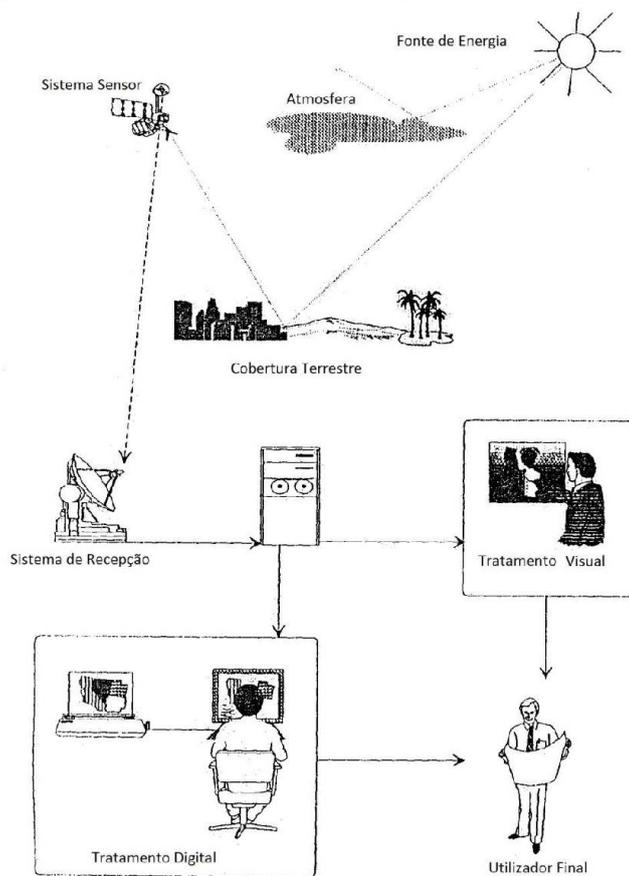
Quase todos os dias podemos ver que a superfície da terra está a mudar rapidamente devido a várias razões em escala local e regional, com repercussões significativas para as pessoas e para o meio ambiente. Para melhor compreender, analisar e prever essas mudanças, as imagens de satélite de detecção remota (DR) são uma fonte inesgotável de informações úteis.

As observações espaciais de DR mudaram fundamentalmente a maneira como os cientistas e planeadores urbanos estudam a terra e os seus ambientes (Jensen e Hodgson, 2004).

Existem muitas maneiras diferentes de definir a DR. Conforme Lillesand *et al.* (2015), detecção remota (DR) é a ciência, o conjunto de tecnologias e a arte de obter informações sobre um objecto, área ou fenómeno, por meio da análise de dados adquiridos por aparelhos de informação (sensores) que não estão em contacto com o objecto, área ou fenómeno sob investigação.

Detecção remota (DR), refere-se a técnicas baseadas em instrumentos empregues na aquisição e medição de informação espacialmente organizada na superfície terrestre, sobre algumas propriedades (espectrais, espaciais, físicas) de uma matriz de pontos alvo (pixéis) em qualquer lugar do universo, que corresponde a classes, características, objectos e materiais, através de um ou mais dispositivos de medição que não estão em contacto físico com os itens sob vigilância (Chuvieco, 1991; Skidmore, 2002). Técnicas de DR envolvem acumular conhecimento pertinente à cena ou alvo detectado através da radiação electromagnética.

Para adquirir imagens da superfície da terra através de sensores instalados em plataformas espaciais, tem de existir uma interacção energética, quer seja por reflexão da energia solar, de uma emissão própria do sensor ou por uma fonte de energia artificial. Conforme Chuvieco (1991), um sistema de DR inclui os seguintes elementos (Figura 1):



**Figura 1:** Componentes de um sistema de detecção remota.

**Fonte:** Chuvieco (1991).

- Fonte de Energia – é a origem da fonte energética detectada pelo sensor. A fonte de energia mais importante é a solar;
- Cobertura Terrestre – formada por diferentes tipos de vegetação, solos, água e construções artificiais, que recebem a emissão energética procedente de fontes de energia e reflectem de acordo com as suas características físicas;
- Sistema Sensor – composto pelo sensor e pela plataforma que o sustenta. Tem como missão captar a energia proveniente da superfície terrestre, codificar e gravar, ou enviar directamente para o sistema de recepção. O sistema sensor pode ser activo se emitir sua própria energia ou passivo se depender duma fonte externa de energia luminosa como o sol;
- Sistema de Recepção – local onde se recebe a informação transmitida pela plataforma, gravando num formato apropriado, podendo-se corrigir ou não, para posterior distribuição ao público;

- Analista – analisa a informação, normalmente em imagens digitais (podem ser também analógicas) convertendo em informação temática ou quantitativa, orientada de forma a facilitar o estudo necessário em gabinete;
- Utilizador Final – encarregue de analisar o documento fruto da interpretação, podendo a partir deste tomar as decisões necessárias para o estudo.

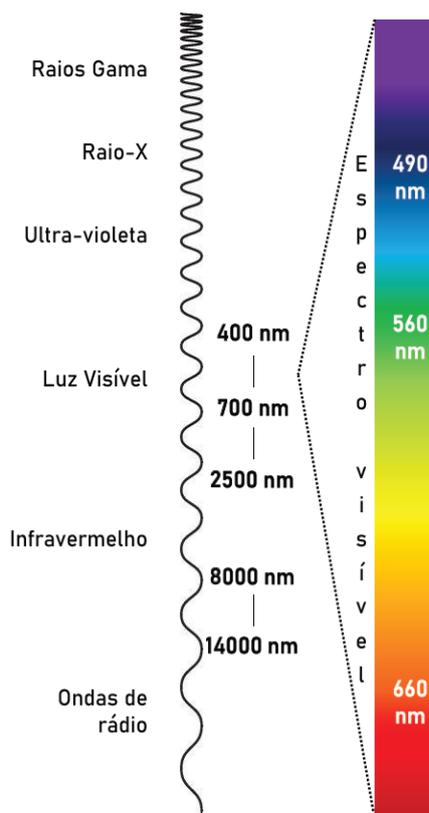
### **2.2.2. Fundamentos de Detecção Remota**

Como dito anteriormente, um dos principais objectivos da DR é a aquisição de informação sobre a superfície da terra para mapeamento e avaliação de recursos terrestres e monitorização ambiental. Todos os materiais, naturais e artificiais, da superfície terrestre, com temperatura superior a 0°C emitem, reflectem, transmitem ou absorvem radiação electromagnética (REM) (Morais, 2002).

Para melhor compreender os fundamentos da detecção remota, é necessário identificar os quatro elementos fundamentais: fonte de energia, sensor, alvo e REM.

Radiação Electromagnética (REM) - na DR, a REM é definida como a energia que interage com a superfície terrestre, sendo ela reflectida, absorvida ou transmitida, permitindo a aquisição de informações das características dos objectos (que se encontram na superfície terrestre) através dos sensores de DR (Anji Reddy, 2008; Bakker *et al.*, 2004). A REM reflectida pode ser ordenada de maneira contínua em função de seu comprimento de onda ou de sua frequência, sendo esta disposição denominada de espectro electromagnético (Moraes, 2002).

Espectro electromagnético - as bandas espectrais das imagens de DR capturam informações sobre a radiação reflectida ou emitida pelos objectos na superfície da terra como corpos de água, solo, vegetação ou fenómenos naturais, em diferentes comprimentos de onda (Jensen, 2015). A Figura 2 ilustra o espectro electromagnético na faixa visível para os seres humanos.



**Figura 2:** Faixa do espectro electromagnético visível aos seres humanos.

**Fonte:** Crusiol *et al.* (2024).

De acordo com Bakker *et al.* (2004) qualidade da imagem é determinada principalmente pelas características do sensor a bordo do satélite, nomeadamente:

- Resolução espacial – refere-se à menor unidade de área medida e indica o detalhe mínimo dos objectos que podem ser distinguidos. Quanto maior for a resolução espacial, menor será o tamanho do pixel e maior serão os detalhes visíveis na imagem;
- Resolução espectral – é a largura das bandas de comprimento de onda espectral às quais o sensor consegue medir. Os satélites com sensores de alta resolução espectral são chamados multiespectrais e são capazes de medir várias bandas desde a faixa do visível até o infravermelho de ondas longas;
- Resolução radiométrica – refere-se à maior ou menor capacidade de o sensor detectar e registar diferenças do nível de radiação espectral recebida.

### 2.3. Sistemas de Informação Geográfica

Os Sistemas de Informação Geográfica (SIG) surgiram na década de 1960 (Longly *et al*, 2005) e actualmente, são uma tecnologia amplamente utilizada em diversas áreas para analisar e monitorar fenómenos ou eventos que ocorrem no espaço e no tempo. Não existe uma definição específica de SIG, no entanto, a maioria das definições sustentam que os SIG são sistemas computacionais voltados para a análise e visualização de dados geográficos.

De acordo com Skidmore (2002), os SIG são um sistema computacional para captura, armazenamento, recuperação, análise e exibição de dados espaciais.

Para Anjy Redy (2002) os SIG são sistemas de suporte à decisão baseados em computadores para colectar, armazenar, apresentar e analisar informações geográficas espaciais.

Segundo Huisman e de By (2009), um SIG é um sistema baseado em computador que fornece recursos para manipular dados georreferenciados, nomeadamente, captura e preparação, gestão, manipulação, análise e apresentação.

A tecnologia de SIG, diferente do mapeamento tradicional, permite a análise espacial dos dados, através dum conjunto de ferramentas desenvolvidas por meio de algoritmos matemáticos que são fundamentais para realizar diversas operações espaciais (Anjy Redy, 2002). Sob essa perspectiva, o SIG constitui uma caixa de ferramentas para o processamento de mapas e conceitos fundamentais, fornecendo uma base para operações analíticas avançadas, envolvendo análise e mensuração espacial (Anjy Redy, 2002).

#### 2.3.1. Modelo de Dados

De acordo com Longly *et al*. (2005) a representação dos elementos geográficos pode ter um formato vectorial (*vector*) ou matricial (*raster*).

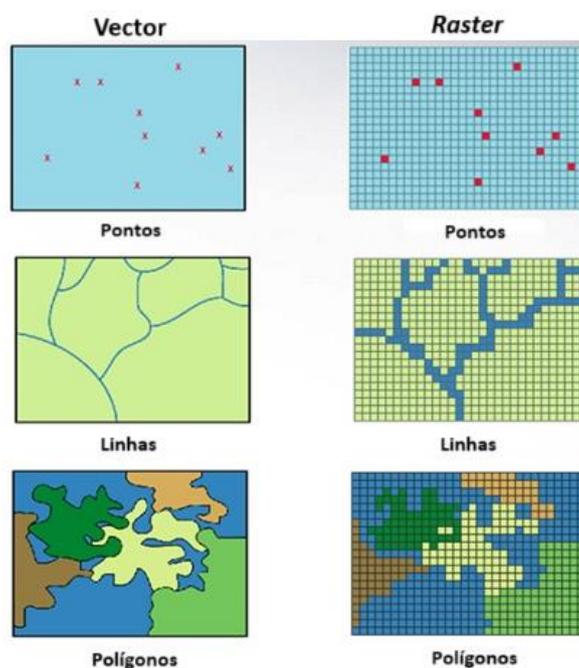
Modelos de dados vectoriais utilizam elementos discretos para representar a geometria de entidades do mundo real através de um conjunto de coordenadas (Bolstad, 2012; Cavalcante e Silva, 2015).

De acordo com Skidmore (2002), em dados vectoriais as unidades básicas de informação espacial são pontos, linhas e polígonos. Pontos são frequentemente usados para definir a localização de objectos pequenos edifícios. Linhas podem ser usadas para representar objectos lineares, como rios ou estradas. Polígonos podem ser usados para representar divisões administrativas como distritos ou bairros.

Os formatos vectoriais são mais indicados para representações de entidades com distribuição espacial exacta, têm uma estrutura de dados compacta e a relação entre os elementos representados (topologia) pode ser descrita explicitamente (Cavalcante e Silva, 2015).

A estrutura de dados matricial ou *raster* é uma abstracção do mundo real, na qual os dados espaciais são expressos como uma matriz de células ou pixels, com a posição espacial implícita na ordenação dos pixels (Bolstad, 2012). As representações *raster* dividem o mundo em matrizes de células e atribuem atributos a elas Skidmore (2002). Uma das formas mais comuns de dados *raster* vem de satélites de DR, que capturam informações nesse formato.

Os formatos matriciais ou *raster* são indicados para representações de grandezas com distribuição espacial contínua (pressão atmosférica, temperatura, etc.), têm uma estrutura de dados simples, permitem a incorporação imediata de dados de sensores remotos e são adequados à análise espacial, face à facilidade de implementação dos algoritmos computacionais necessários a este tipo de análise (Cavalcante e Silva, 2015). Na Figura 3 abaixo são apresentados os modelos de dados vectoriais e matriciais ou *raster* e as suas respectivas feições.



**Figura 3:** Modelo de dados e matricial (*raster*).

**Fonte:** <https://gsp.humboldt.edu/olm/Lessons/GIS/>.

## **2.4. Detecção Remota e Sistemas de Informação Geográfica**

A relação entre as tecnologias de DR e SIG baseia-se no facto de que, para muitas aplicações, a DR pode ser empregada de forma eficaz e eficiente para actualizar camadas de dados do SIG (Anjy Redy, 2002). Essas camadas de dados em um SIG podem, quando empregadas adequadamente, melhorar a interpretabilidade e o potencial de extracção de informações de dados de sensoriamento remoto (Anjy Redy, 2002).

A união entre a DR e SIG fornecendo um ambiente robusto para combinar e analisar informação espacial fornecendo uma base de informação para a gestão de desastres naturais e vários estudos ambientais (Skidmore, 2002). Através da análise de imagens de DR e das ferramentas que os SIG disponibilizam é possível extrair indicadores como rácios de áreas de UCS, informação relativa à organização espacial de uma cidade, a evolução dinâmica do crescimento urbano e os diferentes tipos de UCS.

## **2.5. Pré-processamento de imagem**

O pré-processamento é uma etapa fundamental para assegurar que as análises realizadas sobre as imagens de DR sejam precisas e confiáveis, permitindo uma interpretação mais acurada dos dados. Conforme Jensen (2015), o pré-processamento de imagens em DR consiste em uma série de operações aplicadas as imagens obtidas pelos sensores, com o objectivo de corrigir distorções geométricas (correção geométrica), efeitos atmosféricos (correção atmosférica) e diferenças na intensidade dos pixéis (correção radiométrica). O pré-processamento visa também em minimizar ruídos ambientais que podem ser encontrados nas imagens como nuvens e sombras.

É importante salientar que as operações de pré-processamento dependem do objectivo do estudo e das imagens de satélite utilizadas. Actualmente, a maioria destas operações são realizadas pelas empresas responsáveis pela distribuição dos dados, fornecendo imagens prontas a usar.

## **2.6. Classificação de imagens de detecção remota**

As classes de UCS são normalmente mapeadas a partir de dados de DR, através de métodos baseados em algoritmos de classificação de imagens. De acordo com Lillesand e Kiefer

(1994), o objectivo da classificação é caracterizar automaticamente todos os píxeis da imagem em classes ou temas de UCS. Para cada píxel da imagem é atribuída uma determinada classe ou tema, com base nas características estatísticas dos valores do brilho do píxel (Kamusoko, 2019). Porém, importa distinguir entre classes de informação e classes espectrais.

Classes de informação são categorias de interesse que o utilizador tenta identificar nas imagens, como é o caso de diferentes tipos de floresta, diferentes unidades geológicas ou tipos de rochas, diferentes tipos de produção agrícola (Anderson *et al.*, 1976). Classes espectrais são grupos de píxeis uniformes ou muito semelhantes, caracterizados pelos seus valores de brilho nos diferentes canais espectrais de dados (Jensen, 2015).

Existem várias abordagens de classificação de imagens de DR para produção de mapas de UCS, no entanto as abordagens mais utilizadas são a classificação não supervisionada e classificação supervisionada (Lillesand e Kiefer, 1994; Campbell, 1987).

### **2.5.2. Classificação não supervisionada**

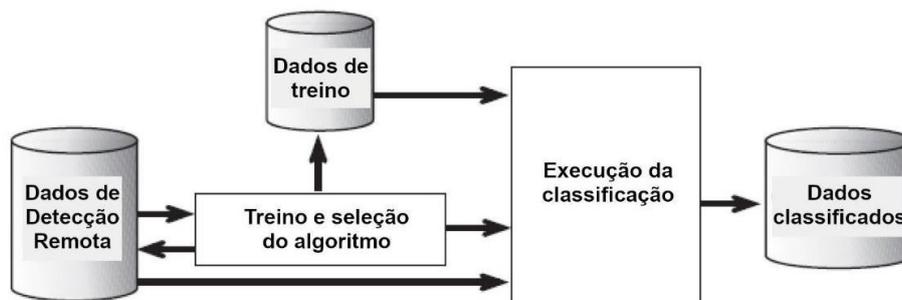
A classificação não supervisionada agrupa píxeis com características espectrais semelhantes em *clusters* únicos, de acordo com alguns critérios determinados estatisticamente, através de um algoritmo não supervisionado e sem os rotular (Jensen, 2015; Kumar *et al.*, 2020). O analista então reclassifica os aglomerados espectrais atribuindo um rótulo para cada classe de informação, onde, o número de classes é determinado pelo agrupamento de dados com características semelhantes.

### **2.5.1. Classificação supervisionada**

A classificação supervisionada é utilizada quando existe um conjunto de dados conhecidos (amostras), necessários para o treino e teste dos classificadores (Borra *et al.*, 2019). Os dados de treino podem ser pontos ou polígonos que representam classes como corpos de água, vegetação, construções urbanas e áreas agrícolas. O algoritmo supervisionado então reclassifica os píxeis da imagem com base na informação fornecida pelas amostras de treino (Canty, 2019). Os parâmetros estatísticos multivariados (médias, desvio padrão, matrizes de covariância, matrizes de correlação) são calculados para cada local de treino, de modo que

cada pixel seja então avaliado e atribuído à classe para qual tem maior probabilidade de ser membro (Jensen, 2015).

De acordo com Bakker *et al.* (2004) a componente mais importante no processo da classificação é o treino em combinação com a selecção do algoritmo. A Figura 4 mostra o processo de classificação supervisionada.



**Figura 4:** Processo de classificação de imagem em detecção remota.

**Fonte:** Bakker *et al.* (2004).

## 2.7. Algoritmos de aprendizagem de máquina para classificação de imagens de DR

A aprendizagem de máquina é uma técnica poderosa para analisar dados de observação da terra, permitindo a classificação de píxeis nas imagens de satélite em duas ou mais categorias (GEE, 2025). A aprendizagem de máquina permite que as máquinas adquiram a capacidade de aprender a realizar tarefas a partir de observações de dados, com pouca necessidade de apoio ou instrução humana directa (Kumar *et al.*, 2020). Os algoritmos de aprendizagem de máquina supervisionados disponíveis no GEE, como Floresta aleatória (RF), Árvores de Classificação e Regressão (CART) e *Naive Bayes* (NB), foram usados para classificar o UCS neste trabalho.

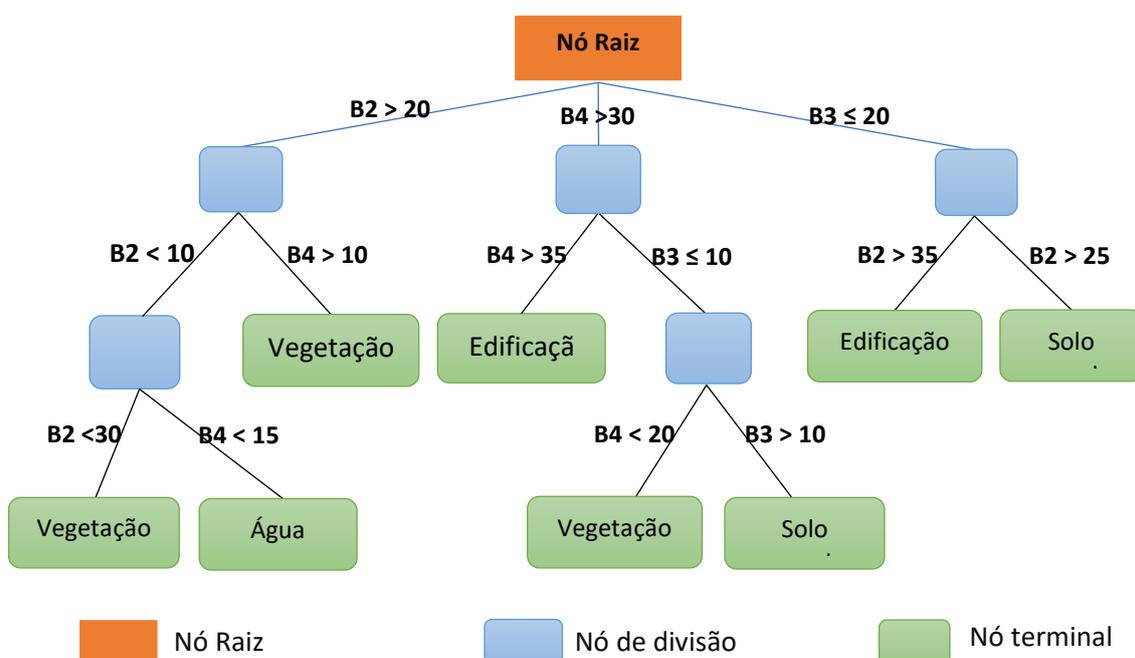
### 2.7.1. Classificador de Floresta Aleatória (RF)

As árvores utilizadas em Florestas Aleatórias (RF) são baseadas no particionamento recursivo binário descrito por Breiman *et al.* (1984). Múltiplas árvores de decisão são geradas utilizando uma selecção aleatória de conjuntos de dados de treinamento e variáveis (Breiman, 2001).

Segundo Cutler *et al.* (2012), em RF árvores particionam o espaço preditor usando uma sequência de divisões binárias em variáveis individuais, onde o nó da árvore (raiz) compreende todo o espaço preditor. Os nós que não são divididos são chamados de “nós terminais” e formam a partição final do espaço preditor. Cada nó não terminal se divide em dois nós descendentes, um à esquerda e outro à direita, de acordo com o valor de uma das variáveis preditoras. Para uma variável preditora contínua, uma divisão é determinada por um ponto de divisão. Os pontos para os quais o preditor é menor que o ponto de divisão vão para a esquerda, os demais vão para a direita.

Para estabelecer a divisão apropriada para a construção de uma árvore, o algoritmo selecciona um conjunto de amostras de treino de forma aleatória (Breiman, 2001). As amostras são seleccionadas através do método *Bootstrap* (amostragem com reposição), isto é, um subconjunto de amostra pode voltar a ser seleccionadas durante a divisão.

De acordo com Breiman (2001), para determinar a classificação final de cada pixel é feita uma votação da maioria dos resultados obtidos pelos subconjuntos de árvores (voto por maioria). Neste processo, quanto maior for o número de árvores maior será a precisão da votação. A Figura 5 abaixo ilustra uma árvore de decisão para a classificação do UCS através do algoritmo RF, onde o nó raiz é composto por um conjunto de amostras de treino para as classes água, solo, vegetação e edificação.



**Figura 5:** Árvore de decisão para classificação do UCS através do RF.

Na Figura 5, o nó raiz é o espaço preditor, composto por amostras e variáveis. O nó de divisão contém um subconjunto aleatório de amostras de duas ou mais classes. O nó terminal é considerado nó puro, as amostras pertencem apenas a uma única classe.

### 2.7.2. **Árvore de Classificação e Regressão (CART)**

CART é também um algoritmo de árvore de decisão binária desenvolvido por Breimane *et al.* (1984) que permite uma tomada de decisão simples em cenários lógicos do tipo se-então. Diferente do RF que opera recursivamente dividindo nós até atingir os nós terminais através de vários subconjuntos de árvore, o CART cria apenas uma única árvore em que a divisão dos nós é baseada em um limite predefinido (Cutler *et al.*, 2012). A escolha do limite predefinido no CART é feita para maximizar a pureza dos grupos através de um índice de impureza, ou seja, minimizar a impureza, separando as amostras da melhor forma possível em cada nó (Cutler *et al.*, 2012). Portanto, algoritmo avalia todas as divisões potenciais para cada nó e escolhe aquela que melhor reduz a impureza. Esse processo continua de forma recursiva até que um nó terminal seja alcançado, com um número mínimo de instâncias.

De acordo com Breimane *et al.* (1984), diferente do RF o CART não selecciona amostras de forma aleatória, o algoritmo utiliza todas amostras disponíveis para construir uma árvore. A eficácia do CART é prejudicada em particular por dados de alta dimensionalidade, que resultam em árvores complexas. Um número elevado de classes pode aumentar profundidade das árvores e reduzir a precisão do resultado. Portanto, o CART é altamente sensível ao tamanho da amostra escolhido para cada classe.

### 2.7.3. **Naive Bayes**

O *Naive Bayes* (NB) é um classificador probabilístico simples baseado na aplicação do teorema de Bayes (da estatística bayesiana) com fortes suposições de independência entre as variáveis de entrada (Murphy, 2012). Uma vantagem do classificador é que requer apenas uma pequena quantidade de dados de treinamento para estimar os parâmetros necessários para a classificação (Murphy, 2012). Apesar da sua simplicidade, o NB pode ter um bom desempenho em tarefas de classificação, especialmente quando o pressuposto de independência se mantém razoavelmente bem (John e Langley, 1995). No entanto, o algoritmo apresenta desvantagens quando a suposição independência (a presença de uma

característica não afecta a presença de outra) nem sempre é realista, pode ter menos precisão se as variáveis forem muito dependentes entre si.

A fórmula do *Naive Bayes* é dada por:

$$P(y | x) = \frac{P(x | y)P(y)}{P(x)}. \quad (1)$$

Onde:

- $P(y | x)$  é a probabilidade posterior de uma classe  $y$ .
- $P(x | y)$  é a probabilidade de observar a classe  $x$  dado que a classe é  $y$ .
- $P(y)$  é a probabilidade a priori da classe  $y$ .
- $P(x)$  é a probabilidade de observar dados da classe  $x$ .

## 2.8. Detecção de mudanças

Uma das vantagens mais poderosas das imagens de DR é a sua capacidade de captar e preservar um registo das condições em diferentes pontos no tempo (Lillesand *et al.*, 2015). Essa capacidade permite a identificação e caracterização de alterações da paisagem da superfície da terra ao longo do tempo e o processo é designado por detecção de mudanças. Desta forma, os processos dinâmicos que ocorrem na superfície terrestre como a mudança na distribuição das espécies de vegetação ou a expansão urbana em áreas rurais e os seus impactos ambientais e sociais podem ser monitorados (Jensen, 2015).

Os métodos de detecção de mudanças em DR e SIG consistem em encontrar discrepâncias entre duas ou mais imagens de satélite, para um determinado período, através de algoritmos de detecção de mudanças disponíveis em softwares de DR e SIG. De acordo com Lillesand *et al.* (2015), é feita uma comparação entre os resultados da classificação de duas imagens de períodos diferentes através de expressões matemáticas simples, onde são identificados quais pixéis mudaram de uma classe para outra. O resultado da comparação (variações entre as classes) pode ser expresso em mapas de detecção de mudanças e as suas áreas podem ser calculadas através da contagem dos pixéis que mudaram da classe A para a classe B.

A Figura 6 mostra duas imagens de satélite tridimensionais da mesma área, de composição de bandas com cores naturais (composição RGB) de períodos distintos, 2002 e 2022. Nessa figura, é notável um elevado acréscimo de infra-estruturas habitacionais de uma imagem

para outra depois de vinte anos. Os métodos de detecção de mudanças descritos acima são utilizados para representar e quantificar essas mudanças.



**Figura 6:** Expansão da área urbana na foz do rio Umbeluzi entre os anos 2002 (esquerda) e 2022 (direita).

**Fonte:** *Google Earth.*

## **2.9. Avaliação da precisão da classificação de imagens**

A avaliação da precisão é muito importante para entender os resultados obtidos e tomar boas decisões. A precisão é determinada pela qualidade das informações temáticas e mapas que são obtidos de dados de DR. Uma imagem classificada ou um mapa de detecção de alterações precisa ser comparado contra dados de referência, assumidos como verdadeiros, para avaliar o seu desempenho e quantificar a sua precisão (Mengistu e Salami, 2007).

De acordo com Congalton e Green (2019), a matriz de confusão é a técnica mais usada para avaliar a precisão dos mapas do UCS. O processo consiste na selecção de uma amostra representativa de elementos no mapa classificado e a comparação destes elementos com os seus valores no mundo real (Lillesand *et al.*, 2015). Como resultado da avaliação a matriz de confusão determina a precisão geral (PG), erro de omissão (EO), erro de comissão (EC) e o coeficiente Kappa (K).

A precisão geral (PG) determina a percentagem de pixéis classificados correctamente, medindo a percentagem da concordância global entre os resultados classificados e os valores reais. Pode ser determinada através da soma dos valores da diagonal principal na matriz de confusão ou através da fórmula:

$$PG = \frac{\text{"Total de Pixéis Classificados Correctamente"}}{\text{"Total de elementos na matriz"}}. \quad (2)$$

O erro de omissão (EO) determina a precisão do produtor, isto é, a percentagem de pixéis de uma classe no mundo real ou dados de referência que foram atribuídos a outra classe (Falsos-Negativos). O erro é determinado através duma fracção entre os Falsos-Negativos (total de pixéis que foram classificados como outra classe) e o total de pixéis que realmente pertencem a essa classe (Total de Pixéis de Referência).

$$EO = \frac{\text{"Falsos Negativos"}}{\text{"Total de pixéis de referência"}}. \quad (3)$$

O erro de comissão (EC) expressa a confusão na classificação de uma classe específica em percentagem. Consiste na determinação da precisão do mapa do ponto de vista do usuário ou consumidor e ocorre quando os pixéis ou amostras que, durante o processo de classificação do mapa foram atribuídos a uma determinada classe (Falsos-Positivos), mas que na realidade pertencem a outra. O erro de comissão é calculado pela fórmula:

$$EC = \frac{\text{"Falsos Positivos"}}{\text{"Total de pixéis classificados na classe"}}. \quad (4)$$

O coeficiente Kappa (K) ou estatística Kappa (K) é uma medida que avalia a qualidade geral do resultado da classificação, através da comparação entre os resultados e os dados de referência. Esta estatística incorpora os elementos fora da diagonal das matrizes de erro e representa a concordância obtida após a remoção da proporção de concordância que poderia ocorrer por acaso. Ou seja, o coeficiente kappa determina o desempenho da classificação em comparação com o aleatório ou uma concordância ao acaso e é calculado pela fórmula:

$$K = \frac{Po - Pe}{1 - Pe}. \quad (5)$$

onde, Po é a precisão observada ou Precisão global (PG), Pe é a concordância casual.

A concordância casual (Pe) é a probabilidade de acertos ao acaso, baseada nas distribuições marginais da matriz de confusão, isto é, o somatório dos produtos das proporções marginais.

O coeficiente Kappa igual a 1 significa concordância perfeita, enquanto um valor próximo a zero significa que a concordância não é melhor do que o seria esperado por acaso. A Tabela 1 apresenta os valores do coeficiente Kappa de acordo com a classificação de Landis e Koch (1977).

**Tabela 1:** Classificação dos valores do coeficiente Kappa.

Valor de Kappa	Qualidade
<0,00	Péssima
0,00 - 0,20	Má
0,20 - 0,40	Razoável
0,40 - 0,60	Boa
0,60 - 0,80	Muito Boa
0,80 - 1,00	Excelente

**Fonte:** Landis e Koch (1977).

### 3. MATERIAL E MÉTODOS

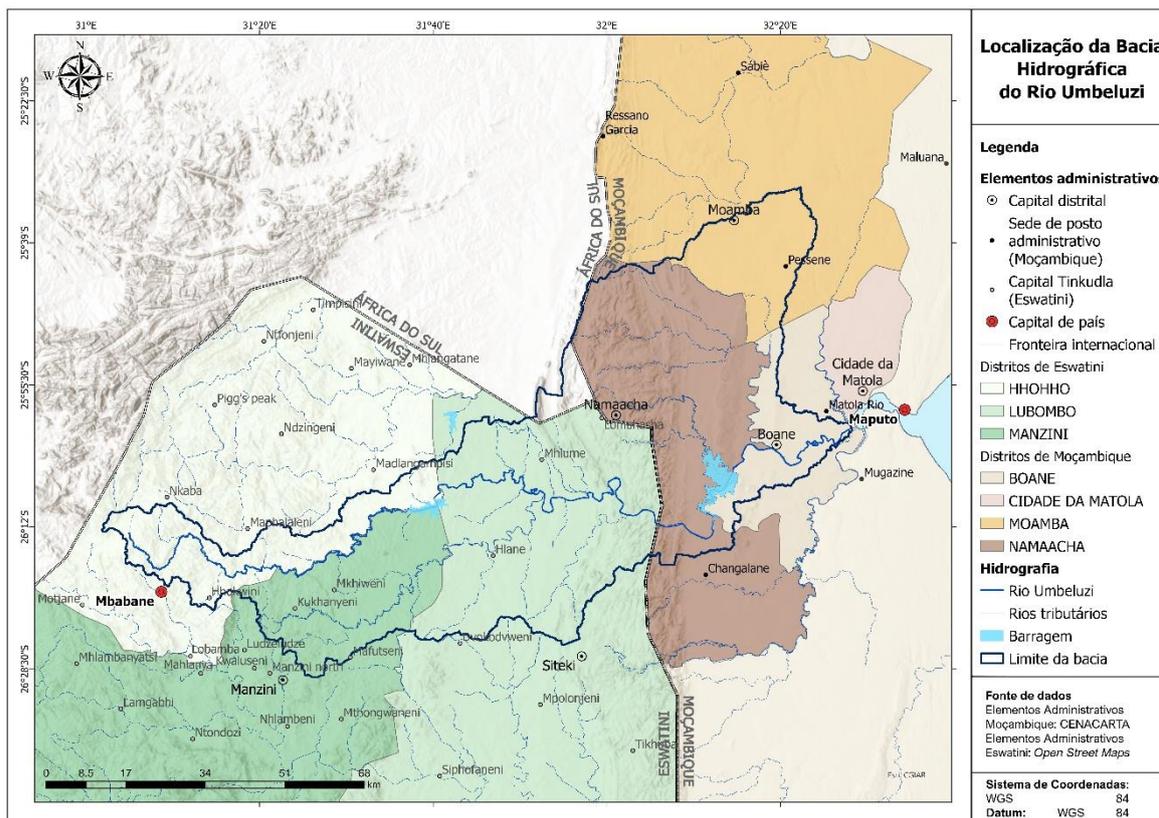
#### 3.1. Descrição da Área de Estudo

A bacia do rio Umbeluzi está geograficamente localizada entre os paralelos 25° e 26° sul e os meridianos 31° e 33° este, cobrindo uma área total de cerca de 5484 km<sup>2</sup> (Figura 7). A bacia tem a sua origem em Eswatini próximo à sua fronteira oeste com a África do Sul. Da área total da bacia, 40% situam-se em Moçambique, 58% em Eswatini e apenas 2% na África do Sul. O curso principal do rio segue predominantemente para este, desaguando no Oceano Índico, via o estuário Espírito Santo, na baía de Maputo, em Moçambique. O rio Umbeluzi tem dois afluentes significativos que são o rio Mbuluzane em Eswatini e o rio Moveene em Moçambique (ARA-SUL, 2014).

A maior altitude da bacia do rio Umbeluzi é de 1828 m acima do nível médio do mar (Cea e Puertas, 2023), localizada no extremo oeste da bacia, na região montanhosa de Eswatini. O ponto mais baixo da bacia situa-se na foz do rio Umbeluzi, no estuário Espírito Santo, baía de Maputo.

Numa escala regional, a bacia do rio Umbeluzi pode ser dividida numa série de áreas com início nas Highveld a oeste, seguindo-se a Middleveld, Lowveld, Libombos e a Planície Litoral a este (ARA-SUL, 2014). A geologia do Umbeluzi é caracterizada por quatro formações geológicas principais que correspondem às áreas que dividem a bacia em faixas orientadas no sentido norte-sul: Achaean (antigas rochas ígneas), o Jurássico (antigos depósitos glaciais, arenitos, riolitos), o Cretáceo (rochas sedimentares) e as Formações Quaternárias (depósitos de aluvião) (ARA-SUL, 2014).

O clima varia de tropical, húmido e seco nas terras altas a oeste, a semi-árido nas Middle e Lowveld (ARA-SUL, 2014). A precipitação varia de 1.500 mm/ano, nas montanhas a 500 mm/ano nas regiões mais baixas. Prevaecem duas estações distintas, a estação chuvosa de Novembro a Abril e a estação seca entre Maio e Outubro (ARA-SUL, 2014).



**Figura 7:** Localização geográfica da bacia hidrográfica do rio Umbeluzi.

### 3.2. Dados

Para a realização do trabalho foram usados os seguintes dados:

- Modelo Digital de Elevação – o Modelo Digital de Elevação (MDE) da *Shuttle Radar Topography Mission* (STRM) da NASA de Fevereiro de 2000, com uma resolução espacial de 30m, disponível no [site https://earthexplorer.usgs.gov](https://earthexplorer.usgs.gov) foi utilizado para a delimitação da bacia hidrográfica do rio Umbeluzi.
- Imagem de Satélite - as imagens do satélite Sentinel-2 foram adquiridas no *Google Earth Engine* (GEE), onde seleccionou-se imagens harmonizadas para o nível de processamento 2A. O nível de processamento 2A fornece imagens que passaram por correcções atmosféricas, geométricas e radiométricas, isto é, são produtos de reflectância de superfície prontos para análise. Estas imagens foram utilizadas para a realização da classificação supervisionada. Os dados do Sentinel-2 fornecem 13 bandas espectrais com uma resolução espacial de 10, 20 e 60 metros. As especificações das bandas do Sentinel-2 podem ser observadas na Tabela 2.

**Tabela 2:** Bandas do Sentinel-2 e suas características.

Banda	Comprimento de onda (nm)	Região do Espectro	Resolução Espacial (m)
B1	443	Aerossol	60
B2	490	Azul	10
B3	560	Verde	10
B4	665	Vermelho	10
B5	705	Borda Vermelha	20
B6	740	Borda vermelha 2	20
B7	783	Borda vermelha 3	20
B8	842	NIR	10
B8A	865	Borda vermelha 4	20
B9	940	Vapor de água	60
B10	1375	SWIR - Cirro	20
B11	1610	SWIR	20
B12	2190	SWIR	10

**Fonte:** *Google Earth Engine.*

- Dados de Divisão administrativa - Os dados em formato *shapefile* da divisão administrativa, nomeadamente sedes distritais, posto administrativo, capital de país, limite distrital e fronteira internacional foram obtidos no Centro Nacional de Cartografia e Teledeteção (CENACARTA) para Moçambique e *Open Street Maps* disponíveis na *web* para Eswatini. Estes dados foram utilizados para elaboração de mapas de divisão administrativa da bacia.

### 3.3. Softwares utilizados

Para o desenvolvimento do trabalho foram usados os seguintes *softwares* e ferramentas:

- *Google Earth Engine* – é uma plataforma baseada em nuvem que permite a aquisição, processamento e análise de grandes conjuntos de dados espaciais, como imagens de satélite através da *API* em *javascript* e *Python*. Esta plataforma foi utilizada para a realização da classificação supervisionada;

- *Google Earth Pro* – é uma ferramenta gratuita da Google que permite visualizar imagens de satélite em séries temporais históricas em modelo tridimensional do terreno. Esta ferramenta foi utilizada no auxílio da colecta amostras de treinamento.
- *ArcGIS Pro 3.2* – da *Environmental Systems Research Institute, Inc* (ESRI), utilizado para o pós-processamento e análise espacial dos resultados obtidos no GEE, para o cálculo de áreas, detecção de mudanças e elaboração de mapas temáticos.
- *Microsoft Excel* – utilizado para elaboração dos gráficos de mudanças do UCS;

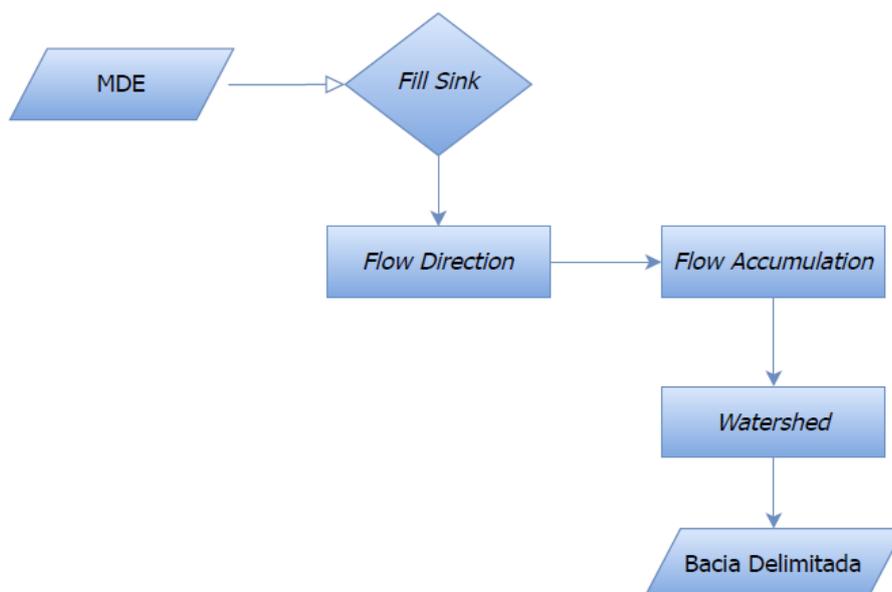
### 3.4. Métodos

#### 3.4.1. Delimitação da bacia hidrográfica

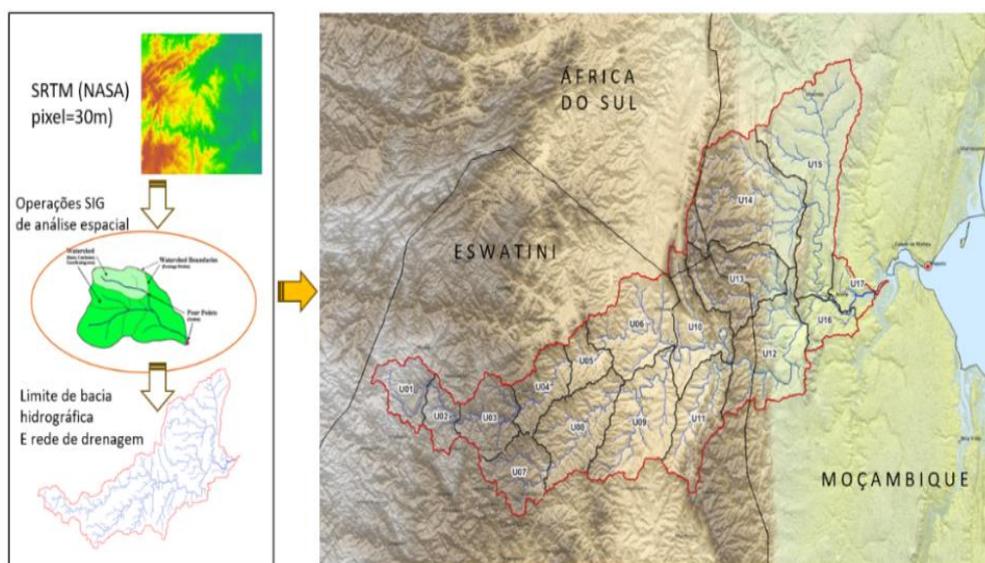
A delimitação da bacia hidrográfica consistiu na identificação do limite que define a área onde as águas superficiais convergem para um único ponto. A delimitação foi feita por meio de processamento do MDE do terreno e técnicas de análise hidrológica no *software* ArcGIS Pro. O procedimento envolveu a aplicação das operações abaixo sobre o MDE:

- *Fill Sink* – consiste em suavizar imperfeições como depressões ou picos que podem ser encontradas no MDE; Depressões e picos são frequentemente erros devido à resolução dos dados ou ao arredondamento das cotas para o valor inteiro mais próximo.
- *Flow Direction* – o fluxo natural da água vai dos pontos mais altos para os pontos mais baixos, portanto, esta ferramenta serve para calcular direcção do fluxo de cada célula para seu vizinho ou vizinhos descendentes;
- *Flow Accumulation* – calcula o fluxo acumulado como o peso acumulado de todas as células que fluem para cada célula descendente no *raster* de saída.
- *Watershed* – delimita a área da bacia hidrográfica. Esta ferramenta suporta apenas uma imagem matricial de direcção de fluxo de entrada do tipo D8.

A Figura 8 ilustra o fluxograma para a delimitação de uma bacia hidrográfica no ArcGIS Pro e na Figura 9 a bacia delimitada.



**Figura 8:** Diagrama de Processos para delimitação de uma bacia hidrográfica no ArcGIS Pro.



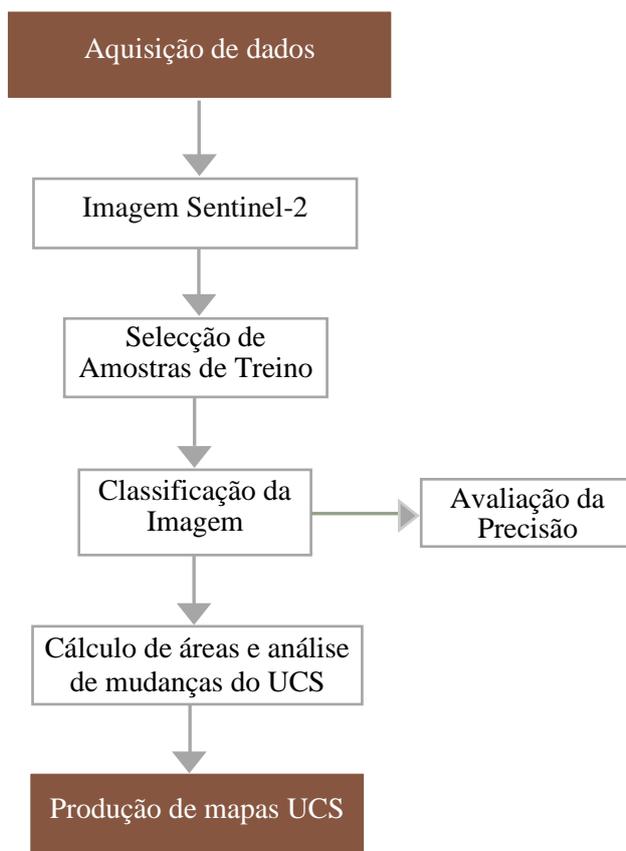
**Figura 9:** Delimitação da bacia hidrográfica do rio Umbeluzi e rede de drenagem.

### 3.4.2. Classificação do uso e cobertura do solo

Para a classificação do UCS foram utilizadas imagens do satélite Sentinel-2 com uma cobertura de nuvens menor que 10% disponíveis na plataforma GEE, onde realizou-se a classificação supervisionada. Para composição da imagem final calculou-se a mediana do conjunto de imagens do Sentinel-2, entre 01/10/2019 a 31/12/2019 para o ano de 2019 e

01/10/2024 a 31/12/2024 para o ano de 2024, através do método “median()” disponível no GEE, conforme implementado em Carvalho *et al.* (2016) e Ouma *et al.* (2023). O método “median()” é usado em colecções de imagens para fazer uma fusão pixel a pixel. Para cada pixel é calculado o valor mediano das imagens que correspondem aquele ponto ao longo do intervalo determinado, resultando em uma imagem única e representativa.

A Figura 10 ilustra o fluxograma dos processos realizados para a obtenção dos resultados do estudo, por forma a facilitar a compreensão, com mais explicações fornecidas nas secções subsequentes.



**Figura 10:** Fluxograma do processo metodológico.

### 3.4.3. Classificação supervisionada

A classificação supervisionada foi realizada com base nos algoritmos de aprendizagem de máquina Floresta Aleatória (RF), Classificação e CART (Árvores de Classificação e Regressão) e NB (*Naive Bayes*) disponíveis no GEE descritos no capítulo 2.

Para a classificação da imagem, foram utilizadas bandas do Sentinel-2 com resolução espacial de 10 metros, nomeadamente: B2 (azul), B3 (verde), B4 (vermelho) e B8 (NIR). Essas bandas são úteis para análises do UCS, fornecendo informações precisas da vegetação, solo, corpos de água e outros tipos de cobertura. Além disso, a resolução espacial de 10 m é a mais alta entre os produtos de satélite disponíveis gratuitamente (Ouma *et al.*, 2023).

#### 3.4.4. Classes de uso e cobertura do solo

Neste estudo, a classificação supervisionada consistiu em representar as seguintes classes: construções urbanas ou edificações, solo exposto, pastagem, corpos de água, vegetação perene, área agrícola irrigada, área agrícola de pequena escala e mangal. A descrição dessas classes de UCS é apresentada na Tabela 3. Esta descrição é feita com base no produto ESA *woldCover* (Zanaga *et al.*, 2021) e Muyambi (2016).

**Tabela 3:** Esquema de classificação do uso e cobertura do solo da bacia do rio Umbeluzi.

<b>Classe do uso e cobertura do solo</b>	<b>Descrição</b>
<b>Construções urbanas</b>	Terrenos cobertos por edifícios, estradas e outras estruturas artificiais, como ferrovias. Os edifícios incluem edifícios residenciais e industriais. O verde urbano (parques, instalações desportivas) não está incluído nesta classe.
<b>Solo exposto ou Pastagem</b>	Terrenos com solo exposto, areia ou rochas e nunca com mais de 10% de cobertura vegetal durante qualquer época do ano ou área geográfica dominada por plantas herbáceas naturais (plantas sem caule persistente ou rebentos acima do solo e sem estrutura firme definida): (pastagens, prados, estepes, savanas) com uma cobertura de 10% ou mais, independentemente de quais sejam as actividades humanas e/ou animais, tais como: pastoreio, manejo selectivo do fogo, etc.
<b>Área agrícola irrigada</b>	A área agrícola irrigada refere-se à área equipada para fornecer água (através de meios artificiais de irrigação, como desvio de rios, inundação ou aspersão) às culturas.
<b>Corpos de água</b>	Esta classe inclui qualquer área geográfica coberta durante a maior parte do ano (mais de 9 meses) por corpos de água: lagos, albufeiras e rios.

<b>Vegetação perene ou bosques</b>	Esta classe inclui qualquer área geográfica dominada por árvores de porte médio com cobertura de 10% ou mais e sempre verdes durante todo ano. Esta classe também inclui a vegetação ribeirinha e de encosta.
<b>Vegetação arbustiva</b>	Esta classe inclui qualquer área geográfica dominada por matagal com uma cobertura igual ou superior a 10%. Arbustos são definidos como plantas lenhosas com caules persistentes e lenhosos e sem caule principal definido e com altura inferior a 5 m. A folhagem do arbusto pode ser perene ou caducifólia.
<b>Terras agrícolas de pequena escala</b>	Terra coberta com culturas anuais que são semeadas/plantadas e passíveis de colheita pelo menos uma vez nos 12 meses após a data de sementeira/plantação. A área de cultivo anual produz uma cobertura herbácea e às vezes é combinada com alguma vegetação arbórea ou lenhosa.
<b>Mangal</b>	Espécies de árvores e outras plantas taxonomicamente diversas e tolerantes ao sal, que prosperam em zonas interditaes de costas tropicais abrigadas, ilhas de inundação e estuários.

### 3.4.5. Amostras de treino

As amostras de treino foram seleccionadas através da utilização de ferramentas de desenho no editor de código do GEE. Para tal, foram identificados pontos de forma representativa dos pixéis que reflectem características de cada classe de UCS sobre a composição natural (RGB) das imagens do Sentinel-2 e imagens do *Google Earth*. No total foram seleccionadas cerca de 2400 amostras para cada ano. Para cada ponto, atribuiu-se um valor numérico correspondente a respectiva classe de UCS.

O número de amostras por classe foi determinado em função da complexidade da classe e área de ocupação da classe. Congalton e Green (2019), recomendam que classes que apresentam maior complexidade recebam mais amostras do que classes mais homogenias. As classes corpos de água, área agrícola irrigada e mangal por apresentarem características muito homogenias e por ocuparem uma extensão pequena dentro da bacia, receberam menos amostras comparativamente a outras classes. As classes solo exposto ou pastagem, construções urbanas, agricultura de pequena escala por apresentarem muita mistura de informação ou ocuparem uma área muito grande, receberam mais amostras.

A selecção de amostras para cada classe foi feita de forma balanceada para toda extensão da bacia de modo a encontrar todas variabilidades espectrais. A Tabela 4 abaixo ilustra o número de amostras por classe e as Figuras 11 e 12 abaixo ilustram os mapas de distribuição espacial das amostras.

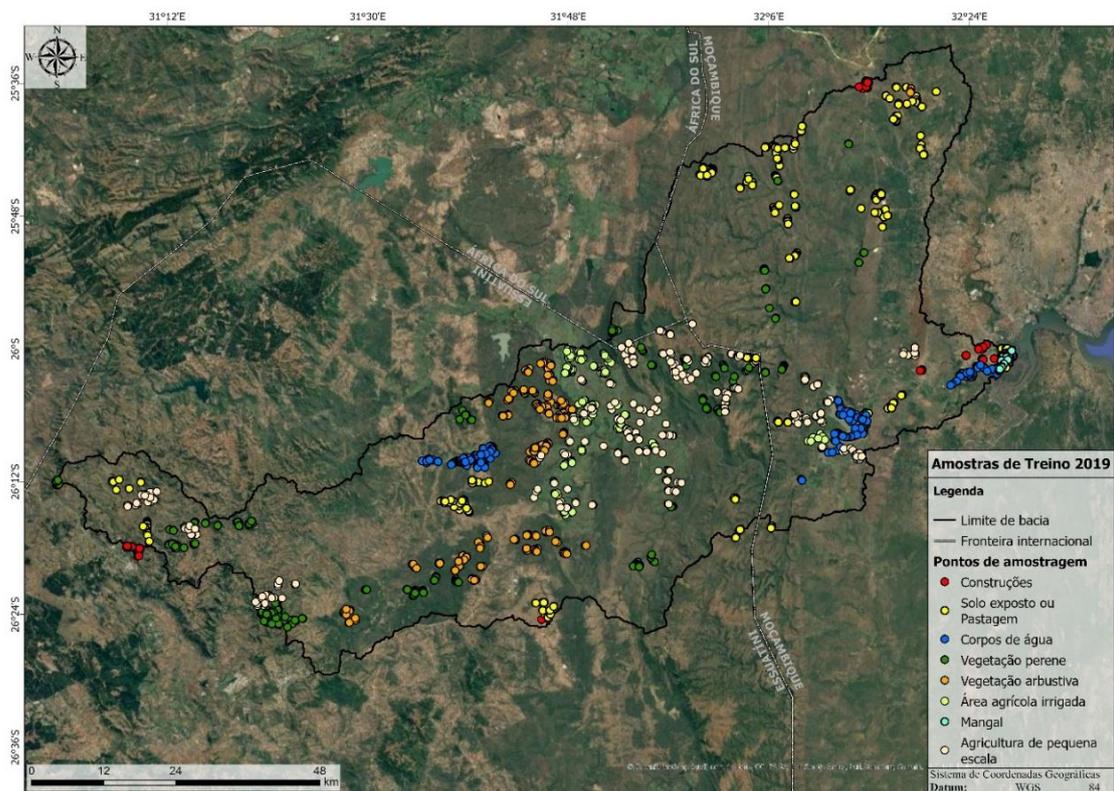
**Tabela 4:** Número de amostras de treino por classe.

<b>Classes de Uso e cobertura do solo</b>	<b>Amostras</b>
Construções urbanas	378
Solo exposto ou pastagem	491
Corpos de água	230
Vegetação perene ou bosques	319
Vegetação arbustiva	322
Área agrícola	158
Mangal	93
Agricultura de pequena escala	419

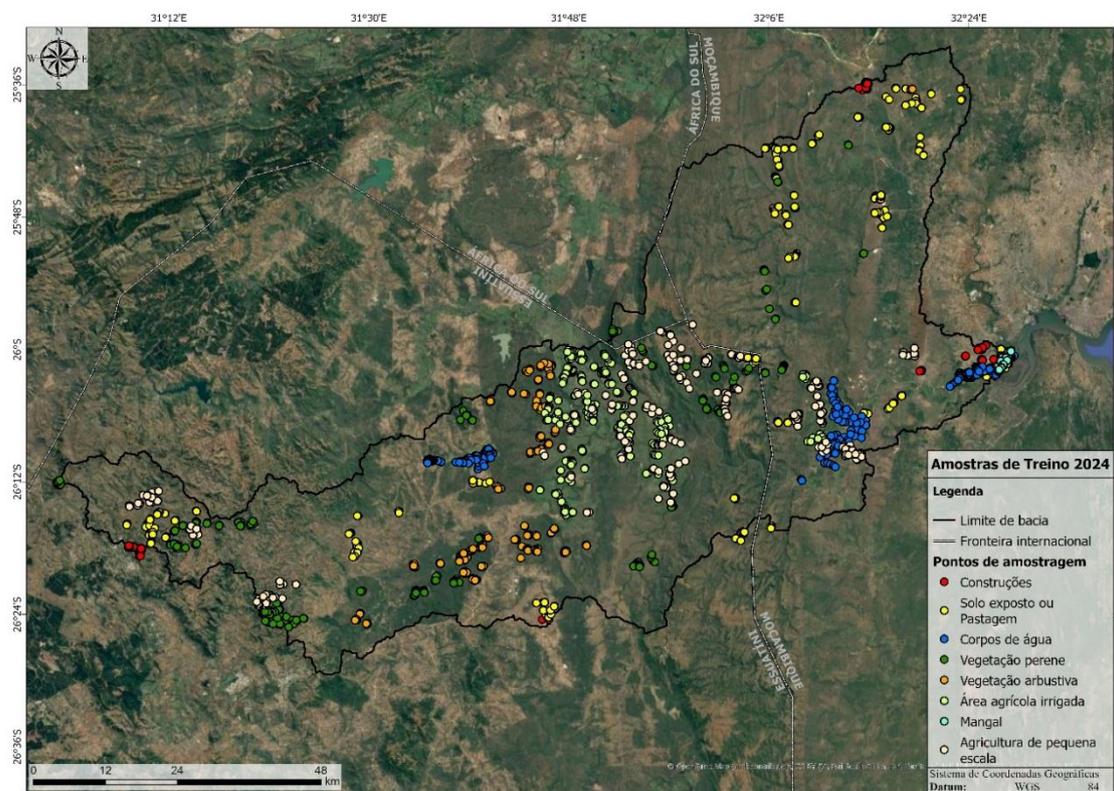
Para os métodos de classificação supervisionada é recomendável que as amostras sejam divididas em duas partes, treinamento (*training set*) e validação (*testing set*). Para este trabalho foram seleccionadas 70% de amostras para treinamento e 30% para validação conforme recomendado por Rodriguez Galiano *et al.* (2012) e Belgiu e Draguţ (2016). Essa divisão permite avaliar a capacidade de generalização do modelo com dados que não foram utilizados durante o treinamento, evitando sobreajustes e garantindo maior precisão na avaliação do desempenho do classificador.

Na classificação através do algoritmo RF foram definidas 100 árvores para o particionamento recursivo. Abaixo encontra-se o *link* com os códigos utilizados para a classificação supervisionada no GEE.

[https://code.earthengine.google.com/?accept\\_repo=users/Yadade94/Umbeluzi-UCS-2019-2024](https://code.earthengine.google.com/?accept_repo=users/Yadade94/Umbeluzi-UCS-2019-2024)



**Figura 11:** Mapa da distribuição espacial das mostras de treino para 2019.



**Figura 12:** Mapa da distribuição espacial das mostras de treino para 2024.

### 3.4.6. Detecção de mudanças

A análise da variação entre as classes de UCS para os anos 2019 e 2024 foi realizada através do método de subtração de áreas no ArcGIS Pro. A fórmula utilizada para o cálculo de mudanças em percentagem é dada por:

$$Mudança = \frac{\text{"Área final"} - \text{"Área inicial"}}{\text{"Área inicial"}}. \quad (6)$$

As áreas das classes da imagem classificada foram calculadas através da contagem do número total de pixels de cada classe multiplicado pela área do pixel.

A identificação de áreas com ganho e perda de cobertura vegetal foi feita por meio de subtração de imagens através da ferramenta para a realização de operações matemáticas em imagens digitais, disponíveis no ArcGIS Pro. Este processo foi realizado individualmente para cada classe, para tal, foi necessário reclassificar as imagens de modo a seleccionar apenas a classe necessária.

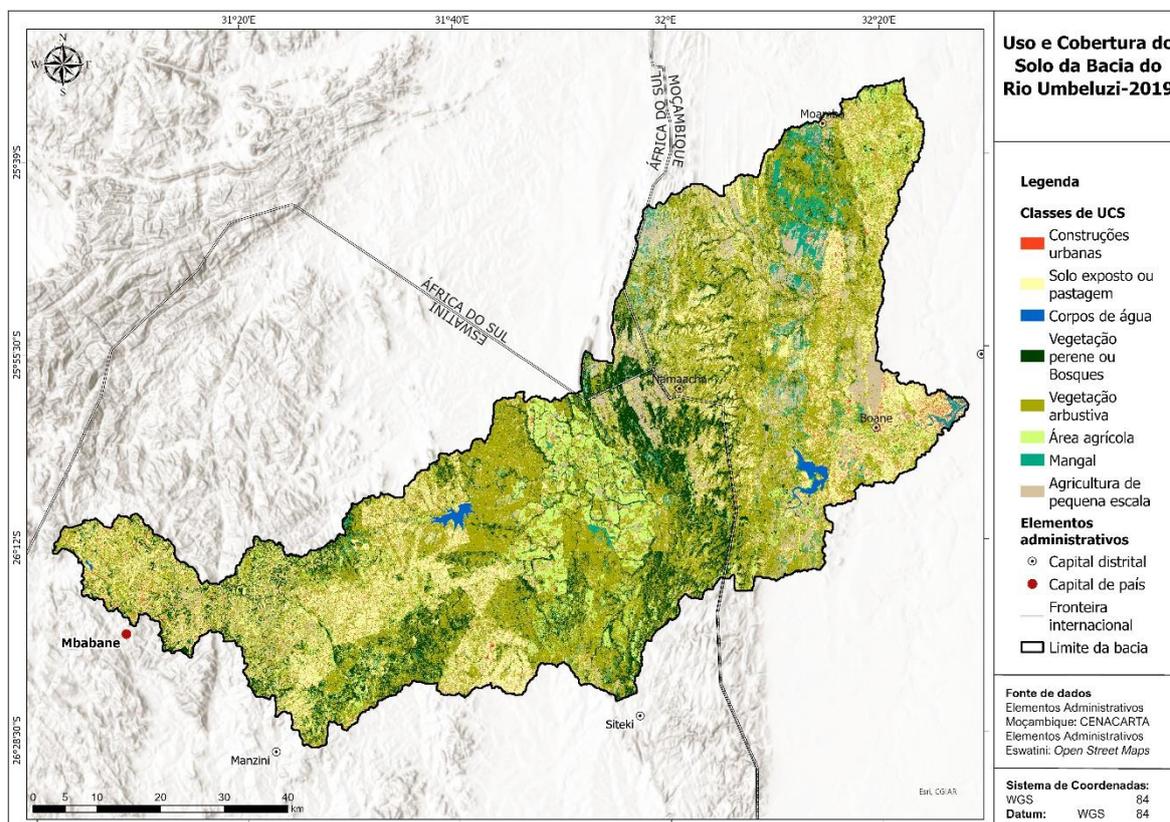
### 3.4.7. Avaliação da precisão e validação dos resultados

A precisão dos algoritmos foi avaliada por meio de uma série de métricas derivadas de uma matriz de confusão conforme descrito na secção 2.9. A qualidade dos mapas do UCS foi avaliada por meio do índice Kappa, precisão geral, erro de omissão e erro de comissão, calculados através da matriz de confusão de forma automática no GEE. A API de classificação supervisionada do GEE dispõe de bibliotecas para calcular automaticamente a matriz de confusão e gerar métricas como precisão geral, erro de omissão, erro de comissão, e índice Kappa.

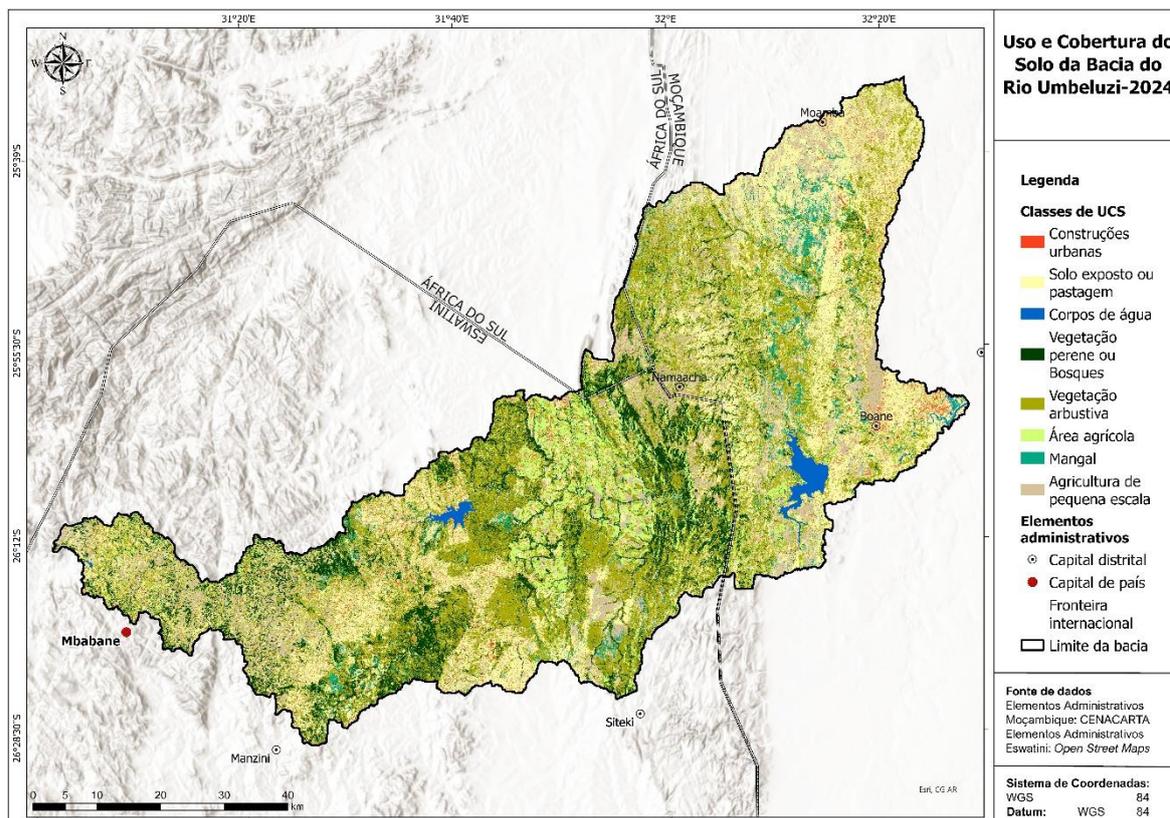
### 3. RESULTADOS E DISCUSSÃO

#### 3.2. Distribuição espacial das classes do uso e cobertura do solo

A distribuição espacial das classes do UCS para os anos 2019 e 2024 é apresentada nas Figuras 13 e 14.



**Figura 13:** Distribuição espacial do uso e cobertura do solo da bacia do rio Umbeluzi para o ano de 2019.



**Figura 14:** Distribuição espacial do uso e cobertura do solo na bacia do rio Umbeluzi para o ano de 2024.

Conforme descrito na secção 3.4.4, a área da bacia em termos do UCS foi dividida em oito classes, nomeadamente: construções urbanas, solo exposto ou pastagem, corpos de água, vegetação perene, área agrícola irrigada, área agrícola de pequena escala e mangal (Figuras 13 e 14). Os resultados revelaram que as classes vegetação arbustiva e solo exposto ou pastagem são as classes dominantes na bacia, tanto para 2019 como para 2024. Estas duas classes representam uma área de 22% e 41% da área total da bacia para o ano de 2019, 27% e 31% para o ano de 2024.

A área da bacia localizada em Eswatini é caracterizada por uma vasta área de cobertura vegetal arbustiva e perene na parte central da bacia, próximo a fronteira com Moçambique e uma vasta área de campos agrícolas tanto irrigados como de pequena escala. As áreas agrícolas de pequena escala encontram-se a sudoeste da bacia juntamente com uma grande extensão de áreas de pasto. As áreas agrícolas irrigadas encontram-se na parte central da bacia, cercadas por vastas áreas de cobertura vegetal perene e arbustiva.

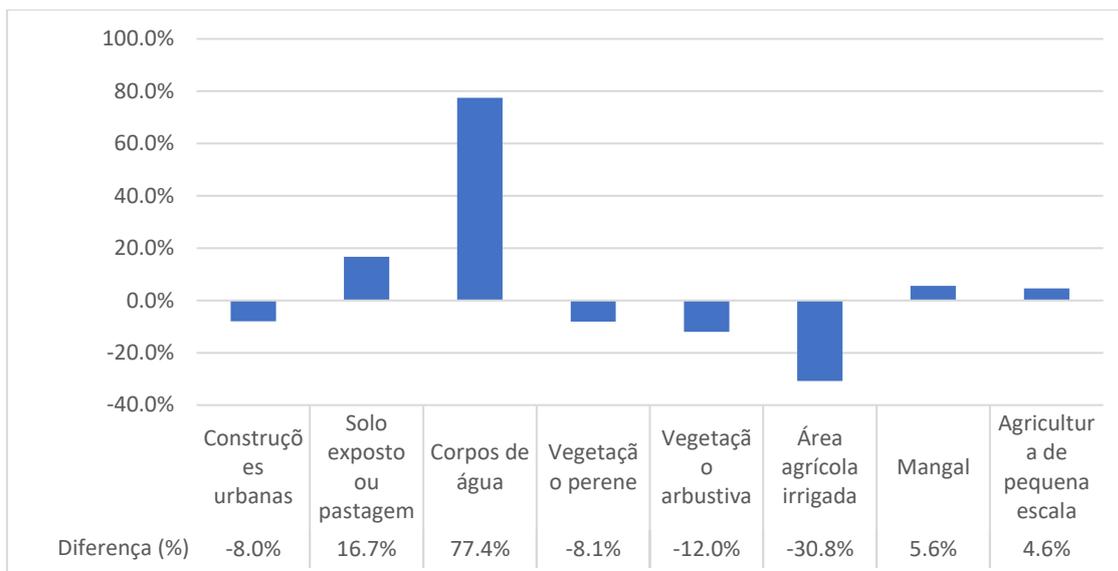
Do lado de Moçambique, a bacia é caracterizada por uma vasta área de pasto, seguida pela cobertura vegetal arbustiva, juntamente com pequenas áreas agrícolas irrigadas ou de pequena escala. Observa-se uma maior densidade de construções urbanas comparativamente a Eswatini.

#### 4.2. Detecção de mudanças

Os dados na Tabela 5 e a Figura 15 ilustram as áreas ocupadas por cada classe de UCS na bacia e as variações ou mudanças dessas áreas entre os anos 2019 e 2024. A área estimada para a bacia é de 5484 km<sup>2</sup>.

**Tabela 5:** Variação de classes de uso e cobertura do solo na bacia hidrográfica do rio Umbeluzi entre os anos de 2019 e 2024.

<b>Ano</b>	<b>2019</b>	<b>2024</b>	<b>Diferença</b>
<b>Classe Uso e Cobertura do solo</b>	<b>Área (km<sup>2</sup>)</b>	<b>Área (km<sup>2</sup>)</b>	<b>Área (km<sup>2</sup>)</b>
Construções urbanas	134.6	123.8	-10.7
Solo exposto ou pastagem	1199.7	1399.5	+199.8
Corpos de água	36.2	64.2	+28
Vegetação perene ou bosques	708.6	651.2	-57.5
Vegetação arbustiva	2228.5	1962	-266.5
Área agrícola irrigada	508.5	351.7	-156.8
Mangal	166.2	175.5	+9.3
Agricultura de pequena escala	501.7	756.2	+254.5
Área total	5484	5484	



**Figura 15:** Mudanças do uso e cobertura do solo da bacia hidrográfica do rio Umbeluzi entre os anos 2019 e 2024.

Os resultados apresentados na Figura 15 e na Tabela 5 mostram mudanças significativas para as classes corpos de água com um incremento de 77.4%, solo exposto ou pastagem com um incremento de 16.7% e a área agrícola irrigada com uma perda de 30.8%.

Em Moçambique e Eswatini, a perda de classes de cobertura vegetal pode estar directamente relacionada com o incremento das áreas agrícolas, extracção de madeira, uso de lenha como carvão vegetal e queimadas descontroladas utilizadas na agricultura e na pastagem (Nhancale *et al.* 2009; ICAT, 2022). O projecto ICAT (2022) no relatório “*Improved land use change maps and annual change methodology Eswatini*” defende que em Eswatini há uma conversão acelerada de áreas florestais ou vegetação nativa em terras agrícolas. Muyambi (2015), destaca o aumento de campos agrícolas como um factor relevante para a perda de áreas de cobertura vegetal e outras classes naturais de UCS.

Embora vários autores defendam um aumento significativo de áreas agrícolas, tanto irrigada como de pequena escala, os resultados mostram uma perda significativa da classe área agrícola irrigada. Esta contradição está relacionada a semelhança espectral entre a área agrícola irrigada e outras classes de cobertura vegetal, o que fez com que certos pixéis correspondentes a áreas agrícolas irrigadas fossem classificados como vegetação perene ou bosques ou ainda vegetação arbustiva, conforme as matrizes de confusão que serão apresentadas na secção 4.2.2.

De acordo com o IFN (2017), Maputo apresenta uma taxa de desflorestamento anual de -1.67%. A mesma fonte defende que Moçambique tem registado uma perda anual da área total dos mangais, porém, os resultados mostram um ligeiro aumento para esta classe. Conforme as Figuras 13 e 14, a classe mangal é confundida com a vegetação herbácea húmida e surge também fora da foz do rio Umbeluzi que é a região onde se encontra esta classe. Portanto, o aumento da humidade no solo pode implicar num incremento de áreas desta classe.

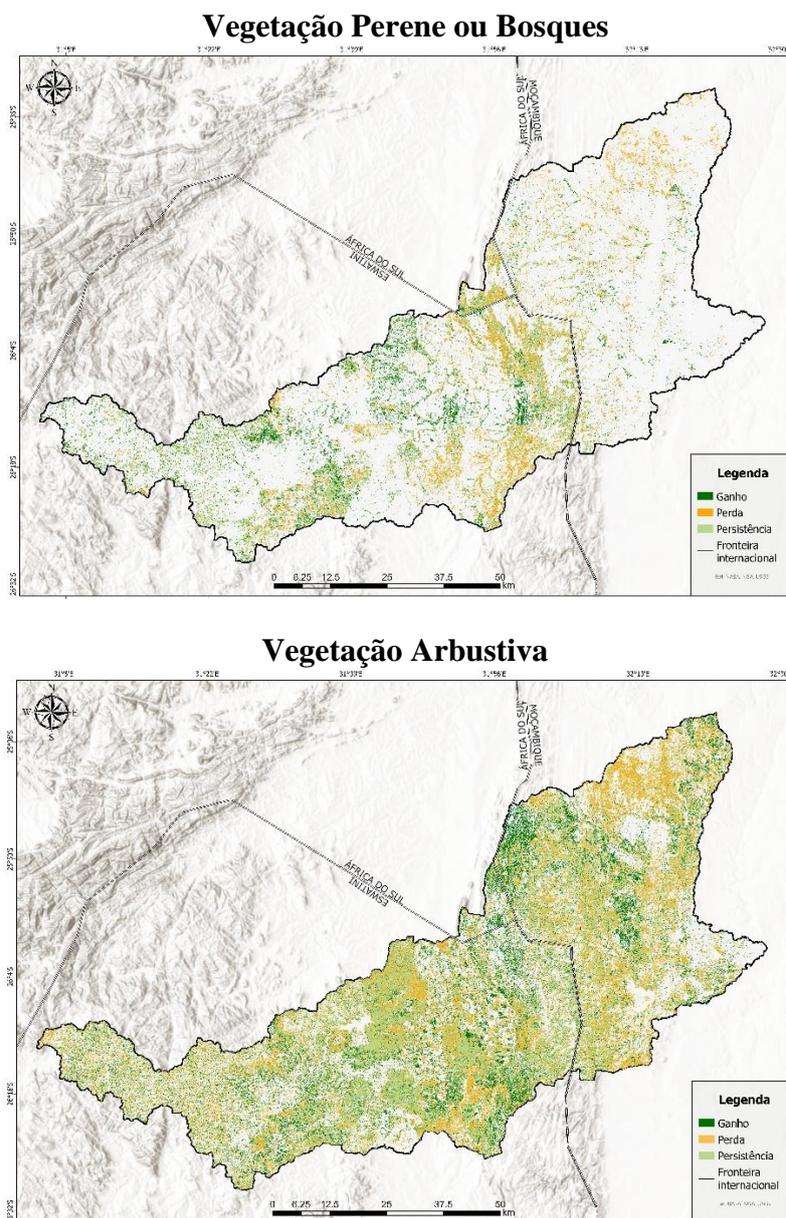
A classe corpos de água aumentou significativamente em 77.4%. O aumento da área de corpos de água pode ser devido a factores como mudanças de padrões de precipitação, bem como, práticas de gestão do consumo da água. Em 2024, a precipitação foi significativamente superior à de 2019, devido às cheias ocorridas na época chuvosa 2023/2024 (INAM, 2019; INAM, 2023). Este facto resultou em problemas de inundações, o que pode ter contribuído para a expansão significativa das áreas de corpos d'água na bacia do rio Umbeluzi.

A classe construções urbanas embora tenha reduzido em cerca de 8%, não condiz com a realidade. Vários estudos e autores tem documentado um aumento de áreas urbanas devido o crescimento populacional, tanto do lado de Eswatini como em Moçambique (Leitão *et al.*, 2021; Muyambi, 2016). Dados do censo de 2017 realizado em Moçambique também mostram um aumento populacional nas zonas pertencentes a bacia do rio Umbeluzi, entre 2007 e 2017 (INE, 2019). Este resultado pode estar relacionado a confusão entre pixéis de áreas de solo exposto com as construções urbanas. Solo exposto e edificações ou estradas apresentaram assinaturas espectrais semelhantes, podendo resultar numa classificação menos precisa.

### **3.2.1. Ganho e perda de cobertura vegetal**

A identificação de áreas com ganhos e perdas de vegetação nativa é de extrema importância para a gestão de uma bacia hidrográfica. A vegetação nativa na bacia do rio Umbeluzi é fundamental para a conservação dos recursos hídricos, protecção de biodiversidade e mitigação de riscos ambientais como a erosão, inundações e secas prolongadas (Rocha *et al.*, 2005; Tucci, 2009). No entanto, vários estudos apontam para perdas significativas de áreas de cobertura florestal para fins agrícolas, produção de carvão vegetal e a expansão urbana (Leitão *et al.*, 2021; Notiço *et al.*, 2021).

A perda da vegetação nativa na bacia do rio Umbeluzi afecta negativamente os ecossistemas e aumenta a vulnerabilidade da bacia a eventos climáticos extremos, como cheias e secas afectando principalmente a Cidade de Maputo que se localiza a jusante da bacia. Os mapas de mudanças da cobertura vegetal ilustrados na Figura 16 abaixo, permitem monitorar áreas com ganhos e perdas da vegetação nativa e tomar decisões que promovem a sustentabilidade do uso do solo da bacia.



**Figura 16:** Mapas com ganhos e perdas da cobertura vegetal na bacia hidrográfica do rio Umbeluzi entre os anos 2019 e 2024.

Os mapas na Figura 16, ajudam a identificar onde houve desmatamento e onde houve regeneração da cobertura vegetal, nomeadamente a vegetação perene ou bosques e a vegetação arbustiva que são as classes de cobertura vegetal dominantes na bacia do rio Umbeluzi.

No mapa de mudanças da vegetação perene ou bosques verifica-se uma grande perda desta cobertura em Eswatini, na área próxima a fronteira com Moçambique e a parte da bacia localizada na África do Sul. O desmatamento verificado pode estar relacionado a expansão dos campos agrícolas irrigados que aumentaram significativamente nessa região. Outro factor relevante é a confusão entre os pixéis da classe vegetação perene e a agricultura irrigada, verificado principalmente no resultado de 2024 conforme será abordado na secção 4.3.1. As características espectrais dessas duas classes por serem muito parecidas fez com que as áreas de vegetação perene ou bosques fossem confundidas com áreas agrícolas irrigadas.

A vegetação arbustiva no mapa de mudanças da Figura 16 acima registou uma grande perda na região noroeste localizada em Moçambique. Conforme o mapa do UCS de 2024 a perda da vegetação arbustiva nessa região deu origem a novos campos agrícolas de pequena escala, áreas de pastagem e novas edificações. Em Eswatini houve também uma perda significativa desta classe, tendo dado origem a novos campos agrícolas irrigados e de pequena escala. Verificam-se também áreas com ganho de vegetação arbustiva, destacando-se a região situada entre a fronteira Moçambique e África do Sul e Moçambique e Eswatini.

O aumento de áreas irrigadas pode aumentar a procura por água, causando redução no escoamento para a foz, o que pode ter impactos de intrusão salina (Molden, 2007; Tucci, 2009). O aumento da procura de água para irrigação pode também implicar em redução da disponibilidade da água para outros usos. Portanto, as áreas irrigadas requerem uma gestão cuidadosa para otimizar o uso da água e evitar desperdícios.

### **4.3. Validação dos resultados**

#### **4.3.1. Comparação de classificadores**

Dos três algoritmos usados (RF, CART e NB) para a classificação supervisionada no GEE, o RF mostrou melhor desempenho com uma Precisão Global (PG) e índice Kappa para a

imagem de 2019 de 0.88 e 0.86 e para a imagem de 2024 uma Precisão Global (PG) e índice Kappa de 0.89 e 0.87 respectivamente.

O algoritmo CART embora tenha apresentado valores satisfatórios, mostrou um desempenho ligeiramente inferior ao RF com uma Precisão Global (PG) e índice Kappa para a imagem de 2019 de 0.84 e 0.81 e para a imagem de 2024 uma Precisão Global (PG) e índice Kappa de 0.86 e 0.83 respectivamente.

Comparativamente ao RF e CART o algoritmo NB mostrou-se menos eficiente, com uma Precisão Global (PG) e índice Kappa para a imagem de 2019 de 0.61 e 0.54 e para a imagem de 2024 uma Precisão Global (PG) e índice Kappa de 0.66 e 0.60 respectivamente. O NB devido a sua simplicidade apresenta limitações quando aplicado a dados de alta dimensionalidade como é o caso das imagens de satélite de DR. O RF e o CART mostraram-se mais robustos nesse contexto em vários estudos. Carvalho *et al.* (2021) e Kipterer *et al.* (2025), compararam vários algoritmos para classificação supervisionada do UCS no GEE, dentre eles o RF, CART e NB, onde o RF e o CART mostraram resultados mais satisfatórios comparativamente a NB.

Nas tabelas abaixo encontram-se descritas as matrizes de confusão e os respectivos erros de omissão (EO) e comissão (EC) para os três algoritmos. A matriz de confusão é uma matriz quadrada onde a linha representa o total de amostras seleccionadas (dados de referência) para cada classe e a coluna o total de pixéis atribuídos a classe ou valores classificados. A diagonal principal mostra o número de pixéis classificados correctamente ou acertos. Portanto, os valores que não fazem parte da diagonal principal expressam a confusão entre as classes e determinam o erro de omissão (linha) e o erro de comissão (coluna) conforme descrito na secção 2.9.

**Tabela 6:** Matriz de confusão da classificação do uso e cobertura do solo da imagem de 2019 com o algoritmo RF.

Classe								
Construções urbanas	103	9	0	0	0	0	0	3
Solo exposto ou pastagem	8	115	0	1	7	0	0	5
Corpos de água	0	0	35	0	0	0	0	0
Vegetação perene ou bosques	0	5	0	81	4	4	2	0
Vegetação arbustiva	0	3	0	5	68	3	0	1
Área agrícola irrigada	0	0	0	4	4	38	0	0
Mangal	0	0	0	0	0	0	34	0
Área agrícola de pequena escala	1	7	0	0	4	0	1	122

**Tabela 7:** Matriz de confusão da classificação do uso e cobertura do solo da imagem de 2024 com o algoritmo RF.

Classe								
Construções urbanas	102	26	0	0	0	0	0	1
Solo exposto ou pastagem	9	131	0	0	1	0	0	3
Corpos de água	0	0	66	0	0	0	0	0
Vegetação perene ou bosques	0	0	0	72	7	3	1	0
Vegetação arbustiva	0	1	0	3	72	1	1	2
Área agrícola irrigada	0	0	0	0	4	42	0	0
Mangal	0	0	0	1	1	0	26	0
Área agrícola de pequena escala	1	10	2	0	2	0	0	118

**Tabela 8:** Erro de omissão e erro de comissão da classificação do uso e cobertura do solo com o algoritmo RF.

Classe	EO 2019	EC 2019	EO 20204	EC 2024
Construções urbanas	0.90	0.92	0.79	0.91
Solo exposto ou pastagem	0.85	0.83	0.91	0.78
Corpos de água	1	1	1	0.97
Vegetação perene ou bosques	0.84	0.89	0.87	0.95
Vegetação arbustiva	0.85	0.78	0.90	0.83
Área agrícola irrigada	0.83	0.84	0.91	0.91
Mangal	1	0.92	0.93	0.93
Área agrícola de pequena escala	0.90	0.93	0.89	0.95

**Tabela 9:** Matriz de confusão da classificação do uso e cobertura do solo da imagem de 2019 com o algoritmo CART.

Classe								
Construções urbanas	102	8	0	0	1	0	0	4
Solo exposto ou pastagem	12	107	0	1	10	0	0	6
Corpos de água	0	0	35	0	0	0	0	0
Vegetação perene ou bosques	0	8	0	78	6	3	1	0
Vegetação arbustiva	0	7	0	13	56	3	0	1
Área agrícola irrigada	0	1	0	2	4	39	0	0
Mangal	0	2	0	0	0	0	32	0
Área agrícola de pequena escala	1	9	0	0	2	0	0	113

**Tabela 10:** Matriz de confusão da classificação do uso e cobertura do solo da imagem de 2024 com o algoritmo CART.

Classe								
Construções urbanas	112	17	0	0	0	0	0	0
Solo exposto ou pastagem	19	113	0	0	3	0	0	9
Corpos de água	0	0	66	0	0	0	0	0
Vegetação perene ou bosques	0	0	0	68	8	5	2	0
Vegetação arbustiva	1	1	0	5	70	1	1	1
Área agrícola irrigada	0	0	0	6	3	37	0	0
Mangal	0	0	0	1	1	1	25	0
Área agrícola de pequena escala	4	10	0	0	1	1	0	117

**Tabela 11:** Erro de omissão e erro de comissão da classificação do uso e cobertura do solo com o algoritmo CART.

Classe	EO 2019	EC 2019	EO 20204	EC 2024
Construções urbanas	0.89	0.89	0.87	0.82
Solo exposto ou pastagem	0.79	0.75	0.78	0.80
Corpos de água	1	1	1	1
Vegetação perene ou bosques	0.81	0.83	0.82	0.85
Vegetação arbustiva	0.7	0.71	0.88	0.81
Área agrícola irrigada	0.85	0.87	0.80	0.82
Mangal	0.94	0.97	0.89	0.89
Área agrícola de pequena escala	0.90	0.91	0.88	0.92

**Tabela 12:** Matriz de confusão da classificação do uso e cobertura do solo da imagem de 2019 com o algoritmo NB.

Classe								
Construções urbanas	76	11	10	0	0	0	4	14
Solo exposto ou pastagem	23	50	0	0	20	6	7	30
Corpos de água	0	0	33	0	0	0	2	0
Vegetação perene ou bosques	0	0	0	70	10	15	1	0
Vegetação arbustiva	0	2	0	3	43	22	10	0
Área agrícola irrigada	0	0	0	21	3	22	0	0
Mangal	3	8	0	0	4	0	19	0
Área agrícola de pequena escala	16	14	0	0	3	0	1	91

**Tabela 13:** Matriz de confusão da classificação do uso e cobertura do solo da imagem de 2024 com o algoritmo NB.

Classe								
Construções urbanas	73	23	5	0	3	0	4	21
Solo exposto ou pastagem	23	91	0	0	1	0	9	20
Corpos de água	6	1	59	0	0	0	0	0
Vegetação perene ou bosques	0	0	0	59	8	15	1	0
Vegetação arbustiva	0	2	0	0	56	11	11	0
Área agrícola irrigada	0	0	0	7	5	29	5	0
Mangal	0	3	0	0	8	3	14	0
Área agrícola de pequena escala	15	27	0	0	6	0	0	85

**Tabela 14:** Erro de omissão e erro de comissão da classificação do uso e cobertura do solo com o algoritmo NB.

Classe	EO 2019	EC 2019	EO 20204	EC 2024
Construções urbanas	0.66	0.64	0.57	0.62
Solo exposto ou pastagem	0.37	0.59	0.63	0.62
Corpos de água	0.94	0.77	0.89	0.92
Vegetação perene ou bosques	0.73	0.74	0.71	0.89
Vegetação arbustiva	0.54	0.52	0.70	0.64
Área agrícola irrigada	0.48	0.34	0.63	0.50
Mangal	0.56	0.43	0.50	0.32
Área agrícola de pequena escala	0.73	0.67	0.64	0.67

Nas matrizes de confusão acima, tanto para a classificação do UCS de 2019 como para 2024, observa-se uma grande confusão entre as classes construções urbanas e a classe solo exposto ou pastagem para os três classificadores. Isto significa que existe uma forte semelhança espectral entre estas duas classes, fazendo com que uma percentagem de pixels que deveriam ter sido classificados como construções urbanas tenham sido classificados como solo exposto ou pastagem e vice-versa. Estradas não pavimentadas e casas cobertas por palha ou chapas de zinco podem ter sido confundidas com áreas de solo exposto, impactando negativamente a acurácia da classificação. Resultados semelhantes foram obtidos por Macarringue *et al.* (2023) e Zafar *et al.* (2024).

Observa-se também uma expressiva confusão entre o solo exposto ou pastagem e a agricultura de pequena escala e uma ligeira confusão entre as construções urbanas e a agricultura de pequena escala. Essa confusão ocorre porque a agricultura de pequena escala

apresenta características que se confundem com o solo exposto ou pastagem e que também se confundem ligeiramente com as construções urbanas. Solo exposto e áreas agrícolas recém preparadas apresentam características muito parecidas e culturas colhidas anualmente confundem-se com pastagens secas. A existência de superfícies descobertas em áreas urbanas ou casas com cobertura de palha ou zinco pode implicar numa confusão com áreas agrícolas em pousio ou em preparo. Estes resultados foram também encontrados por Macarringue *et al.* (2023) e Zang *et al.* (2023).

Para as classes de cobertura vegetal, a vegetação perene ou bosques mostra alguma semelhança espectral com a vegetação arbustiva e a área agrícola irrigada. A vegetação arbustiva mostra uma grande confusão com a vegetação perene ou bosques, área agrícola irrigada e pastagens para os três classificadores. Esta confusão é ainda maior para o resultado de 2019. A área agrícola dependendo do estágio de crescimento da cultura pode ser confundida com a vegetação arbustiva ou vegetação perene ou bosques. Culturas altamente irrigadas como a cana-de-açúcar são facilmente confundidas com a vegetação perene. Estudos realizados por Carvalho *et al.* (2021), Foody (2002) e Xie *et al.* (2008) também obtiveram resultados semelhantes.

As classes mangal e corpos de água por serem muito homogenias apresentaram ligeira ou nenhuma confusão com outras classes.

#### **4.3.2. Avaliação da qualidade dos mapas**

Os mapas de UCS foram classificados através do algoritmo RF por este ter apresentado resultados mais satisfatórios comparativamente aos outros algoritmos. Conforme mencionado na secção anterior, a Precisão Global (PG) e índice Kappa para a imagem de 2019 foi de 0.88 e 0.86 e para a imagem de 2024 foi de 0.89 e 0.87 respectivamente. De acordo com Landis e Koch (1977) valores de índice Kappa entre 0.8 a 1 apresenta uma qualidade excelente.

Para o mapa de UCS de 2019 o maior erro de omissão (EO) pertence as classes área agrícola irrigada, vegetação perene ou bosques, vegetação arbustiva e solo exposto ou pastagem com um erro de 0.83, 0.84, 0.85 e 0.85 respectivamente (Tabela 8). O maior erro de comissão (EC) pertence as classes vegetação arbustiva, solo exposto ou pastagem e área agrícola irrigada com um erro de 0.78, 0.83 e 0.84 respectivamente (Tabela 8).

Para o mapa de UCS de 2024 o maior erro de omissão (EO) pertence as classes construções urbanas com um erro de 0.79 (Tabela 8). O maior erro de comissão (EC) pertence as classes solo exposto ou pastagem e vegetação arbustiva, com um erro de 0.78 e 0.83 respectivamente (Tabela 8).

## 5. CONCLUSÕES E RECOMENDAÇÕES

### 5.1. Conclusões

O objectivo deste trabalho foi analisar a variação de padrões de classes de UCS na bacia hidrográfica do rio Umbeluzi. Para tal, realizou-se a classificação supervisionada através de algoritmos de aprendizagem de máquina no GEE e mapeamento do UCS dos anos 2019 e 2024. Foram comparados três algoritmos supervisionados nomeadamente o RF, CART e o NB, onde o RF apresentou melhor precisão para a classificação e o NB a pior precisão.

A área da bacia em termos do UCS foi dividida em oito classes, nomeadamente: construções urbanas, solo exposto ou pastagem, corpos de água, vegetação perene ou bosques, vegetação arbustiva, área agrícola irrigada, mangal, agricultura de pequena escala.

O resultado da classificação da imagem demonstrou que a maior parte do UCS da área total da bacia hidrográfica do rio Umbeluzi é constituído por cobertura vegetal. Da área da bacia localizada Eswatini, observou-se que a maior área é ocupada por cobertura vegetal arbustiva e áreas de produção agrícola irrigada e de pequena escala, tanto para 2019 bem como 2024. Do lado de Moçambique observou-se que a maior da área é ocupada por solo exposto ou pastagem e cobertura vegetal arbustiva tanto para 2019 como para 2024. A classe construções urbanas reduziu em 8%, solo exposto ou pastagem aumentou em 16.7%, os corpos de água aumentaram em 77.4%, a vegetação perene ou bosques reduziu em 8.1%, a vegetação arbustiva reduziu em 12%, a área agrícola irrigada reduziu em 30.8%, o mangal aumentou em 5.6%, a agricultura de pequena escala aumentou em 4.6%.

As mudanças do UCS na área de estudo podem estar relacionadas a alterações climáticas verificadas nos últimos anos, aumento populacional e práticas do uso do solo para produção agrícola de sequeiro e regadio que são comuns na área da bacia.

Em suma, as técnicas de DR e SIG mostraram-se eficazes na detecção e quantificação de alterações do UCS e na análise das dinâmicas de transformação da paisagem. Os mapas e os dados gerados neste estudo fornecem dados de base importantes para o planeamento e gestão integrada da bacia hidrográfica do rio Umbeluzi. Os resultados deste estudo destacam a importância do monitoramento do UCS como um indicador importante na adopção de políticas sustentáveis para a gestão ambiental da bacia hidrográfica do rio Umbeluzi.

## **5.2. Limitações e Recomendações do estudo**

A semelhança espectral entre as classes de UCS na imagem do Sentinel-2 causou uma grande confusão na classificação de certas áreas de UCS, limitando a qualidade do resultado. Vários pixels que deveriam ter sido classificados como área agrícola irrigada foram classificados como vegetação perene ou bosques ou vegetação arbustiva e vice-versa. A confusão entre estas classes implicou que certas regiões que na realidade são cobertas por vegetação perene ou bosques fossem representadas como áreas agrícolas.

A confusão entre os pixels foi também significativa entre a classe solo exposto ou pastagem e as áreas urbanas. Contudo, as áreas agrícolas e as áreas urbanas mostraram perdas de área para o período em estudo, enquanto, na realidade vários estudos mostram ganhos significativos para estas duas classes ao longo do tempo. A classe mangal, confundiu-se com a vegetação herbácea húmida, fazendo com que áreas cobertas por vegetação herbácea húmida fossem classificadas como mangal.

Adicionalmente, é recomendável que em estudos futuros se incorpore amostras de campo para melhorar a qualidade dos resultados e que se considere a análise de factores socioeconómicos que influenciam as dinâmicas do UCS. Que os resultados deste estudo sejam adoptados como dados de base para a gestão integrada da bacia do rio Umbeluzi pelas partes do governo moçambicano e Eswatini. Além disso, os dados produzidos neste estudo podem ser usados em projectos de contrabalanço para a conservação da biodiversidade e regeneração de áreas degradadas.

## REFERÊNCIAS BIBLIOGRÁFICAS

- Anderson, J. R., Hardy, E. E., Roach, J. T. e Witmer, R. E. (1976). A land use and land cover classification system for use with remote sensor data. U.S. Geological Survey, Professional Paper 964, pp 34.
- Anji Reddy, M. (2002). Textbook of Remote Sensing and Geographical Information System. 2<sup>a</sup> ed. B.S. Publications, Hyderabad, pp 23-27.
- ARA-SUL. (2014). Water Allocation Models for the Umbeluzi River Basin, Mozambique.
- Bakker, W. H., Grabmaier, K. A., Huurneman, G. C., Meer, F. D., Prakash, A., Tempfli, K., Gieske, A. S. M., Hecker, C. A., Janssen, L. L. F., Parodi, G. N., Reeves, C. V., Weir, M. J. C., Gorte, B. G. H., Horn, J. A., Kerle, N., Pohl, C., Ruitenbeek, F. J. e Woldai, T. (2004). Principles of Remote Sensing. ITC Educational Textbook Series, pp 591.
- Belgiu, M. e Draguț, L. (2016). Random forest in remote sensing: A review of applications and future directions. ISPRS journal of photogrammetry and remote sensing, 114, 24-31.
- Bolstad, P. (2010). GIS fundamentals: A first text on geographic information systems (4th ed.). Eider Press.
- Borra, S., Thanki, R. e Dey, N. (2019). Satellite image analysis: clustering and classification. Singapore: Springer, pp 110.
- Breiman, L., Friedman, J., Olshen, R. A. e Stone, C. J. (1984). Classification and regression trees. Routledge.
- Breiman, L. (2001). Random forests. Machine learning, 45, 5-32.
- Campbell, J. B. (1987). Introduction to Remote Sensing. The Guilford Press, New York.
- Campbell, J. B. e Wynne, R. H. (2011). Introduction to remote sensing. Guilford press.
- Canty, M. J. (2019). Image analysis, classification and change detection in remote sensing: with algorithms for Python. Crc Press.

- Cardille, J. A., Crowley, M. A., Saah, D. e Clinton, N. E. (2023). Cloud-based remote sensing with google earth engine: fundamentals and applications. Springer Nature.
- Carvalho, W., Magalhães Filho, F. J. C. e dos Santos, T. L. (2021). Uso e cobertura do solo utilizando a Plataforma Google Earth Engine (GEE): Estudo de caso em uma Unidade de Conservação. *Brazilian Journal of Development*, 7, n° 2, pp 15280-15300.
- Cavalcante, R. e SILVA, G. (2015). Apostila de Introdução ao SIG. Universidade Federal de Minas Gerais, 38.
- Cea, L., Álvarez, M. e Puertas, J. (2024). Using integrated hydrological–hydraulic modelling and global data sources to analyse the February 2023 floods in the Umbeluzi Catchment (Mozambique). *Natural Hazards and Earth System Sciences*, 24(1), 225-243.
- Chuvieco, E. (1991). Fundamentos de teledetección espacial. 3ª ed. Ediciones Rialp, pp 371.
- Congalton, R. G. e Green, K. (2019). Assessing the accuracy of remotely sensed data: principles and practices. 3ª ed. Boca Raton: CRC press, pp 346.
- Crusiol, L., Sibaldelli, R., Nanni, M., franchini, J. e Farias, J. (2024). Conceitos e definições de sensoriamento remoto para monitoramento da soja. Embrapa, Documento pp 461.
- Cutler, A., Cutler, D. R. e Stevens, J. R. (2012). Random forests. Ensemble machine learning: Methods and applications, 157-175.
- Foody, G. M. (2002). Status of land cover classification accuracy assessment. *Remote Sensing of Environment*, 80(1), 185–201.
- Ghaffari, G., Keesstra, S., Ghodousi, J. e Ahmadi, H. (2010). Influence of land use change on soil erosion and sediment yield in the Zanjanrood Basin, Iran. *Agriculture, Ecosystems & Environment*, 137(1–2), 75–85.

- Goodchild, M. F., Longley, P. A., Maguire, D. J. e Rhind, D. W. (2005). Geographic information systems and science. Wiley & Sons, West Sussex, UK, 17, 517.
- Google Earth Engine. (2025). Google Earth Engine. Google. <https://developers.google.com/earth-engine/guides/classification>
- Huisman, O. e de By, R. A. (2009). Principles of geographic information systems. ITC Educational Textbook Series, 1, 17.
- ICAT. (2022). Improved land use change maps and annual change methodology: Eswatini. Disponível em [https://climateactiontransparency.org/wp-content/uploads/2022/09/Activity-4-LULUCF-Land-mapping-methodology\\_Final.pdf](https://climateactiontransparency.org/wp-content/uploads/2022/09/Activity-4-LULUCF-Land-mapping-methodology_Final.pdf)
- INAM. (2019). Actualização da Previsão Climática Sazonal para a NDJ-2018/19 e monitoria da época chuvosa. Maputo: INAM. Disponível em [https://www.inam.gov.mz/index.php/pt/component/edocman/actualizacao-da-previsao-climatica-sazonal-para-a-ndj-2018-19-e-minitoria-da-epoca-chuvosa?Itemid=0:contentReference\[oaicite:5\]{index=5}](https://www.inam.gov.mz/index.php/pt/component/edocman/actualizacao-da-previsao-climatica-sazonal-para-a-ndj-2018-19-e-minitoria-da-epoca-chuvosa?Itemid=0:contentReference[oaicite:5]{index=5})
- INAM. (2023). Monitoria Climática da Província de Maputo: Boletim de Monitoria à Seca. INAM. Disponível em <https://www.inam.gov.mz/index.php/pt/clima/monitoria-de-seca>
- INE. (2019). Censo 2017: Resultados definitivos do IV Recenseamento Geral da População e Habitação. Instituto Nacional de Estatística de Moçambique. Disponível em <https://mozdata.ine.gov.mz>
- Jensen, J. R. e Hogdson, M. E. (2004). Remote sensing of selected biophysical variables and urban/suburban phenomena. *Geography and technology*, pp 109-154.
- Jensen, J. R. (2015). *Introductory Digital Image Processing: A Remote Sensing Perspective*. 4<sup>a</sup> ed. Prentice Hall Press, pp 623.
- John, G. H. e Langley, P. (1995). Estimating continuous distributions in Bayesian classifiers. In *Proceedings of the Eleventh Conference on Uncertainty in Artificial Intelligence* (pp. 338–345). Morgan Kaufmann.

- Kamusoko, C. e Kamusoko, C. (2019). Image classification (pp. 81-153). Springer Singapore.
- Karimi, P., Bongani, B., Blatchford, M. e de Fraiture, C. (2019). Global satellite-based ET products for the local level irrigation management: An application of irrigation performance assessment in the sugarcorn belt of Swaziland. *Remote Sensing*, 11(6), 705.
- Kipterer, J. K., Boitt, M. K. e Mundia, C. N. (2025). Comparative Analysis of Machine Learning Algorithms for Optimal Land Use and Land Cover Classification: Guiding Method Selection for Resource-Limited Settings in Tiati, Baringo County, Kenya. *Journal of Geoscience and Environment Protection*, 13(4), 393-414.
- Kumar, A., Upadhyay, P. e Kumar, A. S. (2020). Fuzzy machine learning algorithms for remote sensing image classification. 3<sup>a</sup> ed. Boca Raton: CRC Press, pp 220.
- Landis, J. R. e Koch, G. G. (1977). The measurement of observer agreement for categorical data. *Biometrics*, v.33, pp 159-174.
- Leitão, P. C., Almeida, C., Neves, R., Cayrol, P., Timóteo, G., & Coelho, H. (2021). Quantificação do impacto da agricultura na qualidade da água do Umbeluzi (Moçambique) usando modelos e imagens de satélite. Instituto Superior Técnico – MARETEC.
- Lillesand, T. M. e Kiefer, R. W. (1994). Remote sensing and image interpretation. 3<sup>a</sup> ed. New York: John Wiley & Sons, pp 750.
- Lillesand, T., Kiefer, R. W. e Chipman, J. (2015). Remote sensing and image interpretation. 7<sup>a</sup> ed. New York: John Wiley & Sons, pp 768.
- Macarringue, A., Mubai, M., Nhantumbo, V. e Manjate, B. (2023). Land Use and Land Cover Change Analysis in the Maputo Province Using Remote Sensing and GIS Techniques. *Journal of African Earth Sciences*, 202, 104972.
- Muyambi, V. N. (2016). Land use and land cover mapping of Eswatini using remote sensing and GIS (Master's thesis). University of Eswatini.

- Moraes, E. D. (2002). Fundamentos de sensoriamento remoto. São José dos campos: INPE, 1-7.
- Molden, D. (Ed.). (2007). Water for food, water for life: A comprehensive assessment of water management in agriculture. London: Earthscan / Colombo: International Water Management Institute.
- Mengistu, D. A. e Salami, A. T. (2007). Application of remote sensing and GIS inland use/land cover mapping and change detection in a part of southwestern Nigeria. *African Journal of Environmental Science and Technology*, v. 1, pp 99-109.
- Meyer, W. B. e Turner, B. L. (1994). Changes in land use and land cover: A global perspective. Cambridge University Press.
- Moraes, E. C. (2002). Fundamentos de Sensoriamento Remoto. Instituto Nacional de Pesquisas Espaciais, pp 22.
- Murphy, K. P. e Learning, M. (2012). A probabilistic perspective. Text book.
- Nhancale, B., Dista, N. e Nazira, D. (2009). Maneio comunitário dos recursos naturais e desenvolvimento de pequenas e médias empresas florestais. Maputo: Instituto de Investigação Agrária de Moçambique.
- Notiço, F. A., Nhancale, B. A. e Macaringue, A. M. (2021). Dinâmica do uso e cobertura do solo na bacia do rio Umbeluzi. Maputo: Eduardo Mondlane University.
- Ouma, Y. O., Keitsile, A., Nkwae, B., Odirile, P., Moalafhi, D. e Qi, J. (2023). Urban land-use classification using machine learning classifiers: comparative evaluation and post-classification multi-feature fusion approach. *European Journal of Remote Sensing*, 56(1), 2173659.
- Rocha, J. (2005). Detecção remota e sistemas de informação geográfica para produção de cartografia de uso e ocupação do solo. *Finisterra*, v. 40, pp 23-39.
- Rodriguez-Galiano, V. F., Ghimire, B., Rogan, J., Chica-Olmo, M. e Rigol-Sanchez, J. P. (2012). An assessment of the effectiveness of a Random Forest classifier for land-

- cover classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 67, 93–104.
- Rogan, J. e Chen, D. (2004). Remote sensing technology for mapping and monitoring land-cover and land-use change. *Progress in planning* 61, pp 301-325.
- Skidmore, A. (2002). *Environmental modelling with GIS and remote sensing*. CRC Press.
- Treitz, P. e Rogan, J. (2004). Remote sensing for mapping and monitoring land-cover and land-use change - an introduction. *Progress in planning* 61, pp 269-279.
- Tucci, C. E. M. (2009). *Gestão de recursos hídricos e bacias hidrográficas (3ª ed.)*. Porto Alegre: UFRGS Editora.
- Xie, Y., Sha, Z. e Yu, M. (2008). Remote sensing imagery in vegetation mapping: a review. *Journal of Plant Ecology*, 1(1), 9–23.
- Zafar, Z., Zubair, M., Zha, Y., Fahd, S. e Nadeem, A. A. (2024). Performance assessment of machine learning algorithms for mapping of land use/land cover using remote sensing data. *The Egyptian Journal of Remote Sensing and Space Sciences*, 27(2), 216-226.
- Zanaga, D., Van De Kerchove, R., De Keersmaecker, W., Souverijns, N., Brockmann, C., Quast, R., Wevers, J., Grosu, A., Paccini, A., Vergnaud, S., Cartus, O., Santoro, M., Fritz, S., Georgieva, I., Lesiv, M., Carter, S., Herold, M., Li, L., Tsendbazar, N. E., Ramoino, F. e Arino, O. (2021). *ESA WorldCover 10 m 2020 v100*.
- Zhang Li, G., F., Jing, Y., Liu, Y., & Sun, G. (2017). Response of evapotranspiration to changes in land use and land cover and climate in China during 2001–2013. *Science of the Total Environment*, 596, 256-265.
- Zhang, Y., Wang, J., Li, X. e Chen, H. (2021). Comparison of land use land cover classifiers using different satellite imagery and machine learning techniques. *Remote Sensing*, 13(19), 4978.