



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS GEODÉSICAS E
TECNOLOGIAS DA GEOINFORMAÇÃO

TÁCITO RICHARLES FERREIRA DA SILVA

**ANÁLISE MULTITEMPORAL DA COBERTURA DO SOLO UTILIZANDO
SENSORIAMENTO REMOTO E APRENDIZADO DE MÁQUINAS: Um estudo de
caso em Barreiros/Pernambuco**

Recife/PE

2025

TÁCITO RICHARLES FERREIRA DA SILVA

**ANÁLISE MULTITEMPORAL DA COBERTURA DO SOLO UTILIZANDO
SENSORIAMENTO REMOTO E APRENDIZADO DE MÁQUINAS: Um estudo de
caso em Barreiros/Pernambuco**

Dissertação apresentada ao Programa de Pós-Graduação em Ciências Geodésicas e Tecnologias da Geoinformação da Universidade Federal de Pernambuco, como requisito parcial para obtenção do título de mestre em Ciências Geodésicas e Tecnologias da Geoinformação.

Área de concentração: Ciências Geodésicas e Tecnologias da Geoinformação

Orientador (a): Profº Dr. Admilson da Penha Pacheco

Recife/PE

2025

.Catalogação de Publicação na Fonte. UFPE - Biblioteca Central

Silva, Tacito Richarles Ferreira da.

Análise multitemporal da cobertura do solo utilizando sensoriamento remoto e aprendizado de máquinas: um estudo de caso em Barreiros/Pernambuco / Tacito Richarles Ferreira da Silva. - Recife, 2025.

108f.: il.

Dissertação (Mestrado)- Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, Programa de Pós-Graduação em Ciências Geodésicas e Tecnologia da Geoinformação, 2025.

Orientação: Admilson da Penha Pacheco.

1. Cobertura do Solo; 2. Sentinel-2; 3. Índices Espectrais; 4. kNN; 5. AHP. I. Pacheco, Admilson da Penha. II. Título.

UFPE-Biblioteca Central

TÁCITO RICHARLES FERREIRA DA SILVA

“Análise multitemporal da cobertura do solo utilizando sensoriamento remoto e aprendizado de máquinas: um estudo de caso em Barreiros Pernambuco”.

Dissertação apresentada à Universidade Federal de Pernambuco como parte dos requisitos para obtenção do título de mestre em Ciências Geodésicas e Tecnologias da Geoinformação.

Aprovada em: 21/8/2025

BANCA EXAMINADORA

Documento assinado digitalmente
 **ADMILSON DA PENHA PACHECO**
Data: 16/09/2025 21:14:42-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Admilson da Penha Pacheco (Orientador)
Universidade Federal de Pernambuco

Documento assinado digitalmente
 **LEIDJANE MARIA MACIEL DE OLIVEIRA**
Data: 22/08/2025 10:22:29-0300
Verifique em <https://validar.iti.gov.br>

Profa. Dra. Leidjane Maria Maciel de Oliveira (Examinadora externa)
Universidade Federal de Pernambuco

Documento assinado digitalmente
 **DIEGO CEZAR DOS SANTOS ARAUJO**
Data: 21/08/2025 16:16:43-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Diego Cezar dos Santos Araújo (Examinador externo)
Universidade Federal de Pernambuco

AGRADECIMENTOS

A concretização deste trabalho só foi possível graças ao apoio, incentivo e colaboração de diversas pessoas e instituições, às quais expresso a minha mais profunda e sincera gratidão.

Primeiramente, agradeço a Deus, pela força e serenidade nos momentos de maior desafio.

Aos meus pais, Minerva e Moisés, pelo amor, sacrifício, incentivo e por serem a base de tudo. Agradeço também a toda minha família, pelo apoio incondicional em cada etapa desta jornada.

Ao meu orientador, Professor Dr. Admilson da Penha Pacheco, pela orientação segura, pela paciência, pelos valiosos ensinamentos e pela confiança depositada em meu trabalho. Sua contribuição foi fundamental para a realização desta pesquisa.

Aos membros da banca examinadora, Professora Dra. Leijdane Oliveira e Professor Dr. Diego César, pelas leituras atentas e pelas contribuições que tanto enriqueceram esta dissertação.

Aos professores do Programa de Pós-Graduação em Ciências Geodésicas e Tecnologias da Geoinformação por todo o conhecimento compartilhado.

Ao apoio direto e essencial de Pedro, Camila, Fábio, Felipe, Guilherme, Joana e Artur.

Aos meus amigos e colegas, pela amizade, pelas palavras de incentivo e pelos momentos de descontração que foram essenciais para manter o equilíbrio.

Por fim, agradeço à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio financeiro, que viabilizou a realização desta pesquisa.

A todos que, direta ou indiretamente, fizeram parte desta conquista, o meu muito obrigado.

RESUMO

A crescente urbanização e a variabilidade climática intensificam os desafios relacionados a cobertura do solo no município de Barreiros, Pernambuco. Diante desse cenário, este estudo teve como objetivo avaliar o comportamento espaço-temporal do uso e ocupação do solo nesta região abrangendo os anos de 2017, 2018 e 2021. A metodologia empregou técnicas de sensoriamento remoto, aprendizado de máquinas e geoprocessamento utilizando imagens Sentinel-2. Para tanto, foram estimados diferentes índices espectrais: Índice de Vegetação por Diferença Normalizada (NDVI), Índice de Diferença Normalizada da Água Modificado (MNDWI), Índice de Construção por Diferença Normalizada (NDBI) e o Índice de Solo Exposto (BSI). Paralelamente, utilizou-se a classificação supervisionada com o algoritmo k-Vizinhos mais próximos (kNN) para o mapeamento de classes de uso e ocupação do solo. De forma complementar, o Processo de Hierarquia Analítica (AHP) foi aplicado para modelar a suscetibilidade às inundações na área de estudo, ponderando fatores condicionantes como hipsometria, uso e cobertura do solo, NDVI, densidade urbana e pedologia. Os resultados da análise multitemporal dos índices espectrais revelaram variações (1,30 %) na cobertura vegetal, (1,04 %) água, e uma contínua expansão das áreas urbanizadas construídas (9,97 %) e redução (7,64 %) do solo exposto ao longo do tempo. O mapeamento com kNN confirmou a notável expansão da área urbana e uma diminuição progressiva da área de água. A precisão do algoritmo demonstrou-se excelente (acurácia global de 95% em 2017, e 100% em 2018 e 2021 para amostras de teste), validando a qualidade dos mapas temáticos produzidos. O mapeamento de suscetibilidade a inundações via AHP identificou as regiões de maior risco concentradas em áreas de baixa altitude, ao longo dos cursos d'água e em zonas urbanizadas, oferecendo um diagnóstico espacial crucial para a gestão local. A modelagem multicritério AHP provou ser uma ferramenta valiosa para a avaliação e o planejamento territorial em Barreiros/PE. O estudo apresenta informações essenciais para o planejamento territorial e a gestão de riscos ambientais, capazes de subsidiar medidas eficazes de mitigação e a promoção de um desenvolvimento urbano mais resiliente e sustentável.

Palavras-chave: Cobertura do Solo; Sentinel-2; Índices espectrais; kNN; AHP.

ABSTRACT

Growing urbanization and climate variability intensify challenges related to land cover in the municipality of Barreiros, Pernambuco. In this context, this study aimed to evaluate the spatio-temporal behavior of land use and land cover in this region, covering the years 2017, 2018, and 2021. The methodology employed remote sensing techniques, machine learning, and geoprocessing using Sentinel-2 imagery. For this purpose, different spectral indices were estimated: Normalized Difference Vegetation Index (NDVI), Modified Normalized Difference Water Index (MNDWI), Normalized Difference Built-up Index (NDBI), and the Bare Soil Index (BSI). Concurrently, supervised classification with the k-Nearest Neighbors (kNN) algorithm was used for mapping land use and land cover classes. Additionally, the Analytic Hierarchy Process (AHP) was applied to model flood susceptibility in the study area by weighting conditioning factors such as hypsometry, land use and cover, NDVI, urban density, and pedology. The results of the multitemporal analysis revealed a 1.30% variation in vegetation cover, a 1.04% reduction in water, a continuous expansion of built-up urbanized areas by 9.97%, and a 7.64% reduction in exposed soil over time. The kNN mapping confirmed the notable expansion of the urban area and a progressive decrease in the water area. The algorithm's accuracy proved to be excellent (global accuracy of 95% in 2017, and 100% in 2018 and 2021 for test samples), validating the quality of the thematic maps produced. The flood susceptibility mapping via AHP identified the highest-risk regions concentrated in low-altitude areas, along watercourses, and in urbanized zones, offering a crucial spatial diagnosis for local management. The AHP multi-criteria modeling proved to be a valuable tool for territorial assessment and planning in Barreiros/PE. The study provides essential information for territorial planning and environmental risk management, capable of supporting effective mitigation measures and the promotion of a more resilient and sustainable urban development.

Keywords: Land Cover; Sentinel-2; Spectral Indices; kNN; AHP.

LISTA DE ILUSTRAÇÕES

Figura 1 - Mapa da Área de Estudo.	26
Figura 2 - Climograma da área de estudo, município de Barreiros/PE – Normais Climatológicas (1991-2020).....	27
Figura 3 - Fluxograma metodológico da pesquisa.....	33
Figura 4 - Mapa do NDVI em Barreiros/PE para o ano de 2017	45
Figura 5 - Histograma do NDVI – 2017.	45
Figura 6 - Mapa do MNDWI em Barreiros/PE para o ano de 2017.	46
Figura 7 - Histograma do MNDWI - 2017.	47
Figura 8 - Mapa do NDBI em Barreiros/PE para o ano de 2017.	48
Figura 9 - Histograma do NDBI - 2017.....	49
Figura 10 - Mapa do BSI em Barreiros/PE para o ano de 2017.	49
Figura 11 - Histograma do BSI - 2017.....	50
Figura 12 - Mapa do NDVI em Barreiros/PE para o ano de 2018.	52
Figura 13 - Histograma do NDVI – 2018.	53
Figura 14 – Mapa do MNDWI em Barreiros/PE para o ano de 2018.....	54
Figura 15 - Histograma do MNDWI – 2018.	54
Figura 16 - Mapa do NDBI em Barreiros/PE para o ano de 2018.	55
Figura 17 - Histograma do NDBI – 2018.	56
Figura 18 - Mapa do BSI em Barreiros/PE para o ano de 2018.	57
Figura 19 -Histograma do BSI – 2018.	57
Figura 20 - Mapa do NDVI em Barreiros/PE para o ano de 2021.	60
Figura 21 – Histograma do NDVI - 2021	61
Figura 22 - Mapa do MNDWI em Barreiros/PE para o ano de 2021.	62
Figura 23 - Histograma do MNDWI – 2021.	62
Figura 24 - Mapa do NDBI em Barreiros/PE para o ano de 2021	63
Figura 25 - Histograma do NDBI – 2021.	64
Figura 26 - Mapa do BSI em Barreiros/PE para o ano de 2021.	65
Figura 27 - Histograma do BSI – 2021.....	65
Figura 28 - Mapa de Uso e Ocupação do Solo - Classificação kNN (2017).....	71
Figura 29 - Mapa de Uso e Ocupação do Solo - Classificação kNN (2018).....	74
Figura 30 - Mapa de Uso e Ocupação do Solo - Classificação kNN (2021).....	77
Figura 31 - Matriz de Confusão - kNN (2017).....	84
Figura 32 - Matriz de Confusão - kNN (2018).....	85
Figura 33 - Matriz de Confusão - kNN (2021).....	85
Figura 34 - Mapa de Hipsometria - AHP.	90
Figura 35 - Mapa de uso e cobertura do solo - AHP.	91
Figura 36 - Mapa de NDVI - AHP.....	92
Figura 37 - Mapa de Densidade Urbana - AHP.....	93
Figura 38 - Mapa de Pedologia - AHP.....	94
Figura 39 - Mapa de Suscetibilidade a Inundações em Barreiros/PE.	95

LISTA DE ILUSTRAÇÕES

Gráfico 1 - Distribuição percentual das classes – Classificação kNN (2017)	72
Gráfico 2 - Distribuição percentual das classes – Classificação kNN (2018)	75
Gráfico 3 - Distribuição percentual das classes – Classificação kNN (2021)	79
Gráfico 4 - Distribuição percentual das classes por ano – Classificação kNN (2017-2021).	80
Gráfico 5 - Desempenho do kNN por número de vizinhos (k) – Ano: 2017.....	82
Gráfico 6- Desempenho do kNN por número de vizinhos (k) – Ano: 2018.....	83
Gráfico 7 - Desempenho do kNN por número de vizinhos (k) – Ano: 2021.....	83

LISTA DE TABELAS

Tabela 1 - Escala de ponderação de Saaty.	24
Tabela 2 - Índice Randômico do AHP em função do tamanho da matriz.	24
Tabela 3 - Especificações das imagens Sentinel-2.	29
Tabela 4 - Bandas e resoluções do MSI Sentinel-2.	30
Tabela 5 - Intervalos de NDVI para uso e ocupação do solo.	35
Tabela 6 - Distribuição de amostras de treinamento e validação por classe e ano (2017-2021).	39
Tabela 7 - Estatísticas descritivas dos Índices Espectrais – 2017.	51
Tabela 8 - Distribuição percentual dos pixels por intervalo de valores dos Índices Espectrais - 2017.	51
Tabela 9 - Estatísticas descritivas dos Índices Espectrais – 2018.	58
Tabela 10 - Distribuição percentual dos pixels por intervalo de valores dos Índices Espectrais - 2018.	58
Tabela 11 - Estatísticas descritivas dos Índices Espectrais – 2021.	66
Tabela 12 - Distribuição percentual dos pixels por intervalo de valores dos Índices Espectrais – 2021.	66
Tabela 13 - Estatísticas descritivas por ano dos Índices Espectrais – (2017-2021).	68
Tabela 14 - Distribuição percentual dos pixels por intervalo e ano de valores dos Índices Espectrais (2017-2021).	69
Tabela 15 - Distribuição quantitativa das classes do LULC - Classificação kNN (2017).	72
Tabela 16 - Distribuição quantitativa das classes do LULC - Classificação kNN (2018).	75
Tabela 17 - Distribuição quantitativa das classes do LULC - Classificação kNN (2021).	78
Tabela 18 – Comparativo da distribuição das classes do LULC - Classificação kNN (2017-2021).	80
Tabela 19 – Relatório das métricas de desempenho consolidado – 2017, 2018 e 2021.	84
Tabela 20 – Pesos finais dos Fatores Condicionantes.	88

LISTA DE ABREVIATURAS E SIGLAS

AHP — Analytic Hierarchy Process (Processo de Hierarquia Analítica)

APAC — Agência Pernambucana de Águas e Clima

BSI — Bare Soil Index (Índice de Solo Exposto)

CNN — Convolutional Neural Networks (Redes Neurais Convolucionais)

Colab — Google Colaboratory

EMBRAPA — Empresa Brasileira de Pesquisa Agropecuária

ESA — European Space Agency (Agência Espacial Europeia)

GPU — Graphics Processing Unit (Unidade de Processamento Gráfico)

IBGE — Instituto Brasileiro de Geografia e Estatística

IC — Índice de Consistência

IPCC — Intergovernmental Panel on Climate Change (Painel Intergovernamental sobre Mudanças Climáticas)

kNN — k-Nearest Neighbors (k-vizinhos mais próximos)

LULC — Land Use and Land Cover (Uso e Cobertura do Solo)

MDT — Modelo Digital de Terreno

MNDWI — Modified Normalized Difference Water Index (Índice de Água por Diferença Normalizada Modificado)

MSI — Multi-Spectral Instrument (Instrumento Multiespectral)

NDBI — Normalized Difference Built-up Index (Índice de Construção por Diferença Normalizada)

NDVI — Normalized Difference Vegetation Index (Índice de Vegetação por Diferença Normalizada)

NIR — Near Infrared (Infravermelho Próximo)

OSGeo — Open Source Geospatial Foundation

QGIS — Quantum Geographic Information System

RC — Razão de Consistência RED —

RF — Random Forest

SAR — Synthetic Aperture Radar (Radar de Abertura Sintética)

SR — Sensoriamento Remoto

SVM — Support Vector Machine (Máquina de Vetores de Suporte)

SWIR — Short-Wave Infrared (Infravermelho de Ondas Curtas)

TPU — Tensor Processing Unit (Unidade de Processamento de Tensores)

SUMÁRIO

1.	INTRODUÇÃO	13
2.	OBJETIVOS	17
2.1.	OBJETIVO GERAL.....	17
2.2.	OBJETIVOS ESPECÍFICOS	17
3.	REVISÃO DA LITERATURA	18
3.1.	DINÂMICA DO USO E COBERTURA DO SOLO	18
3.2.	SENSORIAMENTO REMOTO E ÍNDICES ESPECTRAIS	19
3.3.	CLASSIFICADOR K-NEAREST NEIGHBORS (kNN)	22
3.4.	PROCESSO DE HIERARQUIA ANALÍTICA (AHP)	23
3.5.	AVALIAÇÃO DE ACURÁCIA DE CLASSIFICADORES	25
4.	METODOLOGIA.....	26
4.1.	ÁREA DE ESTUDO	26
4.2.	MATERIAIS	28
4.2.1.	Dados Orbitais.....	28
4.2.2.	Softwares e Ferramentas	30
4.3.	PROCEDIMENTOS METODOLÓGICOS	33
4.3.1.	Índices Espectrais	35
4.3.2.	Classificador k-Nearest Neighbors (kNN).....	37
4.3.2.1.	Preparação das amostras de treinamento e validação	39
4.3.3.	Validação da Acurácia da classificação.....	39
4.3.4.	Processo de Hierarquia Analítica (AHP) para mapeamento de Suscetibilidade.....	40
5.	RESULTADOS E DISCUSSÃO	44
5.1.	ANÁLISE DOS ÍNDICES ESPECTRAIS E CARACTERIZAÇÃO DA COBERTURA DO SOLO	44
5.1.1.	Distribuição espacial dos Índices Espectrais – 2017	44
5.1.2.	Estatísticas descritivas e distribuição percentual dos Índices Espectrais - 2017	50
5.1.3.	Distribuição espacial dos Índices Espectrais – 2018.....	52

5.1.4.	Estatísticas descritivas e distribuição percentual dos Índices Espectrais - 2018	58
5.1.5.	Distribuição espacial dos Índices Espectrais – 2021	59
5.1.6.	Estatísticas descritivas e distribuição percentual dos Índices Espectrais – 2021	66
5.1.7.	Síntese e tendências temporais dos Índices Espectrais (2017-2021)	67
5.2.	CARACTERIZAÇÃO ESPAÇO-TEMPORAL DO USO E OCUPAÇÃO DO SOLO COM KNN	70
5.2.1.	Mapas Temáticos de Uso e Ocupação do Solo – 2017.....	70
5.2.2.	Análise quantitativa das classes do LULC – 2017.....	72
5.2.3.	Mapas Temáticos de Uso e Ocupação do Solo – 2018.....	73
5.2.4.	Análise quantitativa das classes do LULC – 2018.....	75
5.2.5.	Mapas Temáticos de Uso e Ocupação do Solo – 2021.....	77
5.2.6.	Análise quantitativa das classes do LULC – 2021.....	78
5.2.7.	Síntese e tendências temporais do LULC (2017-2021).....	80
5.2.8.	Avaliação da precisão da classificação do kNN	82
5.2.8.1.	Otimização do parâmetro k	82
5.2.8.2.	Avaliação da precisão da classificação do kNN	84
5.3.	ANÁLISE DO MAPA DE SUSCETIBILIDADE VIA AHP	87
5.3.1.	Ponderação dos Fatores Condicionantes.....	88
5.3.2.	Mapa de Suscetibilidade a Inundações	94
6.	CONSIDERAÇÕES FINAIS	96
	REFERÊNCIAS.....	98

1. INTRODUÇÃO

A rápida urbanização das cidades é uma tendência universal, que apresenta problemas e desafios significativos a serem enfrentados pelos planejadores urbanos (Wu et al., 2020). Essa expansão populacional global impulsiona a alteração do uso da terra e a ocupação desordenada de áreas vulneráveis (Hussein et al., 2018; Lefulebe et al., 2023). O aumento no número de edifícios residenciais, rotas de transporte, comerciais e industriais, característicos da rápida urbanização, ocasiona uma redução significativa de terras vagas e a alteração do uso da terra (Lefulebe et al., 2023), causando graves impactos, como deslizamentos de terra (Hirye et al., 2023). A conversão de superfícies naturais em áreas impermeáveis impacta o balanço de radiação na interface terrestre e pode perturbar a recarga da água subterrânea, elevando o risco de eventos hidrológicos extremos (Kotarba et al., 2016; Su et al., 2022). O incremento de áreas impermeáveis em uma bacia hidrográfica, por sua vez, eleva o risco de inundações (Walega et al., 2019).

No contexto do Brasil, a região Nordeste, e especialmente Pernambuco, tem enfrentado recorrentes inundações nas últimas décadas, decorrentes das mudanças no uso e ocupação da terra e das variações climáticas (Alves et al., 2024). O município de Barreiros, localizado na Bacia Hidrográfica do Rio Una, em Pernambuco, é particularmente vulnerável a eventos de inundação devido à alta irregularidade da precipitação (APAC, 2013). A crescente ocupação urbana com aterros e construções às margens dos rios tem intensificado os riscos de enchentes (Londe et al., 2015). Entre 1989 e 2021, Barreiros registrou uma recorrência de 18 eventos de inundação (Alves, 2022), refletindo uma tendência global de aumento de inundações em áreas urbanas (Wu et al., 2020; Moniruzzaman, 2020). O processo de urbanização não apenas modifica as características hidrológicas das cidades, mas também intensifica a ocorrência de eventos de precipitação extrema em áreas urbanas, ocasionando um aumento na frequência e antecipação dos picos de inundação (Zhang et al., 2023). As consequências das inundações e outras atividades antrópicas nesta última década tem alterado sistematicamente a cobertura do solo em Barreiros/PE.

O conhecimento das mudanças no uso e cobertura da terra (em inglês, Land Use and Land Cover, LULC) é essencial em diversos campos, com base no uso de observações da Terra, como planejamento urbano e regional, vulnerabilidade ambiental e avaliação de impacto, monitoramento de desastres e perigos naturais e

estimativa da erosão do solo e salinidade (Talukdar, et al., 2020). A avaliação quantitativa e a previsão da dinâmica do LULC são os meios mais eficientes para gerenciar e compreender a transformação da paisagem (Mas, et al 2017).

O mapeamento das mudanças no LULC foi identificado como um aspecto essencial de uma ampla gama de atividades e aplicações, como no planejamento do uso da terra ou na mitigação do aquecimento global (Dutta, et al, 2027; Talukdar et al., 2020). Sendo, portanto, uma ferramenta de análise ambiental com o intuito de visualizar as perdas de biodiversidade, vegetação, recursos hídricos e alterações climáticas, além o impacto social causado pela urbanização (SCHNEIDER et al., 2016).

Uma das consequências das mudanças climáticas é o aumento da variabilidade espacial e temporal da água, bem como de eventos extremos, em frequência e intensidade (Fabian et. al 2023; Rukundo et al, 2016). A variabilidade climática e as alterações no uso do solo desempenham um papel significativo nas inundações (IPCC, 2022). Os eventos de chuva aumentaram em frequência e intensidade nas últimas décadas na maior parte da superfície da Terra, com os dados observacionais disponíveis identificando tendências nas alterações climáticas induzidas pelo homem como o principal fator (IPCC,2022; Anik, et al., 2023).

Diante da complexidade dos impactos da urbanização em áreas de risco e da urgência em mitigar seus efeitos, o Sensoriamento Remoto (SR) surge como uma ferramenta fundamental. Ele oferece a capacidade de coletar dados abrangentes e em tempo real sobre as condições climáticas, o uso da terra e a dinâmica do escoamento superficial em áreas urbanizadas (Zhao et al., 2019; Dodangeh et al., 2020).

Vários satélites com diferentes características espaciais e espectrais têm sido utilizados em estudos de uso e ocupação do solo e inundações. O satélite Sentinel-2, por apresentar imagens de livre acesso com resolução espacial média de 10 e 20 metros nas faixas espectrais do visível e infravermelho próximo, tem favorecido diversas pesquisas de avaliação multitemporal da cobertura do solo (Phiri, et al., 2020).

As técnicas de SR a partir de índices espectrais derivados de imagens de satélites tais como NDVI, MNDWI, NDBI e BSI tem sido utilizado com êxito para identificar, monitorar e avaliar áreas a cobertura temporal do solo (Atefi & Miura, 2022). Um índice espectral pode ser definido como uma operação matemática aplicada a um

conjunto de duas ou mais observações espectrais por pixel para obter uma evidência considerável (Prasad et al., 2022; MONTERO et al., 2023). A combinação de reflectâncias em diferentes bandas espectrais, por meio de índices espectrais desempenha um papel crucial na análise de séries temporais de imagens de satélite (LAONAMSAI et al., 2023). Várias equações de índices espectrais ideais para diversos campos de aplicação foram produzidas, e constantemente são desenvolvidos e testados novos índices espectrais (Montero et al., 2023).

Vários estudos têm apresentado o potencial da integração de dados de sensoriamento remoto com métodos de aprendizado de máquinas para mapear diferentes recursos naturais (Shirmard, et. al., 2022). O uso de algoritmos de aprendizado de máquinas em conjunto com índices espectrais tem demonstrado maior precisão na análise de uso e ocupação do solo (Abdi, 2022).

De acordo com VARUN & R. NISHA (2011) as técnicas de classificação por aprendizado de máquinas são usadas para encontrar um modelo ou função que possa explicar e caracterizar os conceitos ou classes de dados de forma precisa e específica para determinados propósitos. O classificador mais direto nas técnicas de aprendizado de máquina é o k - vizinho mais próximo (kNN) (CUNNINGHAM & DELANY, 2021). Contudo, o método possui desafios conhecidos, como a sensibilidade a classes desbalanceadas (Zhang et al., 2019). O KNN classifica objetos com base em dados de aprendizagem de qual é a distância mais próxima do objeto (LUBIS; LUBIS & AL-KHOWARIZMI, 2020). Além disso, no método KNN, o processo de aprendizado envolve a localização de um ponto no espaço, determinado pela classe mais frequentemente encontrada entre os dados vizinhos mais próximos desse ponto. Seu emprego é, portanto, fundamental para diagnosticar a dinâmica de LULC em Barreiros-PE, fornecendo subsídios essenciais para o planejamento territorial e a gestão de riscos ambientais.

A análise multicritérios com abordagem espacial têm sido comumente utilizada para planejamento do desenvolvimento, ocupação e uso da terra, no estudo e seleção de áreas aptas a diferentes usos em avaliações de impacto ambiental, além da aptidão ou não de áreas para implementação de construções privadas e/ou públicas (Collins, Steiner & Rushman, 2001). Entre os métodos de análise multicritérios mais difundidos e utilizados globalmente, o Processo Analítico Hierárquico (AHP) foi desenvolvido por Thomas L. Saaty na década de 1980, nos Estados Unidos. Trata-se de uma metodologia voltada para solução de problemas de escolha, aplicada para diversas

situações onde existam estruturas complexas. De acordo com Leal (2017), o método AHP entrega informação cruciais nas análises de geoambientais e áreas de suscetibilidade. O método AHP analisa matematicamente comparações pareadas entre fatores em conjunto aos julgamentos e pesos de especialistas para avaliar critérios qualitativos ou intangíveis (Chai et al., 2013; Leal, 2019).

Neste contexto, este estudo tem como objetivo geral avaliar o comportamento espaço-temporal do uso e ocupação do solo no Município de Barreiros/Pernambuco, abrangendo os anos de 2017, 2018 e 2021. Para isso, foram empregadas imagens Sentinel-2, os índices espectrais NDVI, NDBI, MNDWI e BSI, a técnica de classificação k-vizinho mais próximo (kNN) e o Processo de Hierarquia Analítica (AHP) para o mapeamento de suscetibilidade a inundações. A pesquisa busca identificar as variações na cobertura do solo e os fatores que influenciam essas mudanças ao longo do tempo, fornecendo informações essenciais para o planejamento territorial e a gestão de riscos ambientais, visando a promoção de um desenvolvimento urbano mais resiliente e sustentável.

2. OBJETIVOS

2.1.OBJETIVO GERAL

Avaliar o comportamento espaço-temporal do uso e ocupação do solo no Município de Barreiros/Pernambuco nos anos 2017, 2018 e 2021 utilizando sensoriamento remoto e aprendizado de máquinas. O estudo envolveu imagens Sentinel-2, os índices espectrais NDVI, NDBI, MNDWI, BSI, a técnica de classificação k-vizinho mais próximo (kNN) e o Processo de Hierarquia Analítica (AHP).

2.2.OBJETIVOS ESPECÍFICOS

- Definir parâmetros de análise que permitam a diferenciação de classes de uso do solo, com base na variação dos índices espectrais e séries temporais;
- Avaliar os índices espectrais NDVI, NDBI, NDWI, BSI e a classificação supervisionada kNN para o mapeamento de uso e ocupação do solo;
- Caracterizar o Processo de Hierarquia Analítica (AHP) em estudo de áreas passíveis à inundação no Município de Barreiros/Pernambuco;
- Apresentar um panorama das transformações temporais da cobertura do solo na área de estudo no período pré-definido na pesquisa.

3. REVISÃO DA LITERATURA

3.1. DINÂMICA DO USO E COBERTURA DO SOLO

As mudanças de Uso e Cobertura do Solo (LULC) são processos dinâmicos acelerados por diversos fatores, que incluem o manejo florestal, a pecuária e a agricultura, mas são particularmente intensificadas pela expansão urbana (Lefulebe et al., 2023).

A expansão urbana, associada a processos demográficos progressivos, bem como a processos econômicos, sociais ou políticos, é um processo dinâmico e complexo que frequentemente tem efeitos adversos nas mudanças no uso da terra (Sapena & Ruiz, 2019). Em países em desenvolvimento, espera-se que essas mudanças ocorram de forma rápida, principalmente como resultado do crescimento das cidades, impulsionado pela migração rural-urbana e por elevadas taxas de natalidade (Lefulebe et al., 2023). Essa urbanização não apenas ocasiona uma redução significativa de terras vagas, mas também promove a alteração do uso da terra (Lefulebe et al., 2023), com graves impactos ambientais, como deslizamentos de terra e perturbações no ciclo hidrológico (Hirye et al., 2023).

Esse processo de urbanização leva não apenas a uma redução significativa de terras vagas e agrícolas, mas também à ocupação de áreas naturalmente vulneráveis, como planícies de inundação e encostas ímremes (Hussein et al., 2018), constituindo um referencial teórico fundamental para a análise das transformações geoespaciais na área de estudo, e resultando em graves impactos ambientais, como deslizamentos de terra e profundas perturbações no ciclo hidrológico (Hirye et al., 2023).

De acordo Wiatkowska et al., (2021), a expansão urbana contribui para o aumento de superfícies impermeáveis, como edifícios, estradas, estacionamentos, infraestrutura técnica etc., que são os indicadores do grau de urbanização, refletindo a qualidade ambiental das áreas urbanas. Por sua vez, o crescimento da área construída afeta, entre outras coisas, a dinâmica do escoamento superficial, o aumento da poluição, a gestão da água e a estrutura e o funcionamento da cidade (Wiatkowska et al., (2021). Assim, os tipos de cobertura do solo e a configuração espacial de suas estruturas afetam a qualidade de vida humana (Larondelle, 2014).

Segundo Fenta et al., (2017), a perspectiva de mudança em áreas de uso e ocupação do solo (LULC), a mudança induzida pela expansão urbana tem efeitos consideráveis que impactam o meio ambiente, o ecossistema e a sociedade (Grimm

et al. 2008; Wilson e Chakraborty 2013). Esses impactos são particularmente importantes em países em desenvolvimento, onde há capacidade limitada para lidar com as consequências ambientais e sociais da rápida expansão urbana (Cohen, 2006). As implicações hidrológicas dessas transformações são diretas e bem documentadas. A urbanização é identificada como a principal causadora de alterações nos processos hidrológicos e hidráulicos, resultando na redução da capacidade de drenagem e no consequente aumento de inundações súbitas em áreas urbanas (Zope et al., 2016).

O processo de conversão de superfícies naturais em áreas impermeáveis não apenas modifica as características hidrológicas das cidades, mas também intensifica a ocorrência e antecipa os picos de inundação (Zhang et al., 2023). Isso acarreta um aumento no volume total de escoamento e na descarga máxima dos eventos de tempestade (Ali et al., 2011), elevando o risco geral de inundações na bacia hidrográfica (Walega et al., 2019). Grandes eventos de inundação, com perdas econômicas e vítimas humanas, têm sido amplamente registrados em áreas altamente urbanizadas como consequência direta dessa dinâmica (Wu et al., 2020; Moniruzzaman, 2020).

Adicionalmente, a variabilidade climática desempenha um papel significativo e potencializador. O aumento na frequência e intensidade de eventos de chuva, observado nas últimas décadas e associado a alterações climáticas induzidas pelo homem (IPCC, 2022; Anik, et al. 2023), agrava ainda mais o risco de inundações repentinas, especialmente quando associado ao aumento da área impermeável em uma bacia de captação (Rahman et al., 2023).

3.2.SENSORIAMENTO REMOTO E ÍNDICES ESPECTRAIS

O monitoramento contínuo das mudanças no Uso e Cobertura do Solo (LULC) tornou-se uma necessidade global para a gestão de recursos naturais e a avaliação de impactos de mudanças climáticas, especialmente em um cenário de rápida urbanização e crescimento populacional (Zafar et al., 2024). Neste contexto, o Sensoriamento Remoto (SR) por satélite consolidou-se como a tecnologia mais eficaz para a aquisição de informações sobre a dinâmica da superfície terrestre em larga escala, permitindo a criação de produtos de mapeamento de LULC cada vez mais precisos (Wang et al., 2023).

A utilização de sensores ópticos, notadamente com imagens disponíveis gratuitamente que oferecem cobertura global e curtos ciclos de revisita, tem desempenhado um papel fundamental no apoio ao desenvolvimento urbano sustentável (Albertini et al., 2022). Essas imagens são cruciais para estimar a cobertura vegetal, monitorar a degradação florestal e mapear a expansão urbana, proporcionando alternativas de baixo custo para estudos ambientais e urbanos (Souza et al., 2024). Em uma importante revisão, Albertini et al. (2022) destacaram as tendências de pesquisas com imagens ópticas de livre acesso para a delimitação da extensão da água e o monitoramento de inundações.

Os índices espectrais urbanos apresentaram melhorias promissoras nas últimas duas décadas em estudos de uso e cobertura do solo urbano por meio de mapeamento, estimativa, detecção de mudanças, análise de séries temporais, dinâmica urbana, monitoramento, modelagem e assim por diante (Javed, et. al., 2021). De acordo com estes autores, os índices espectrais de sensoriamento remoto são não supervisionados, imparciais, rápidos, escaláveis e quantitativos na extração de informações. A revisão apresentada por Javed et al., (2021) abrange aplicações dos índices espectrais urbanos, a seleção de índices com base nas bandas espectrais disponíveis e seus méritos e deméritos. Sendo, portanto, bastante significativa. De forma complementar, a revisão de Kaur & Pandey (2022) aprofunda a análise ao focar especificamente nos índices espectrais voltados para a extração de áreas construídas (*built-up areas*).

O Normalized Difference Vegetation Index (NDVI) é um dos mais consolidados para a análise da vegetação (Rouse et al., 1974). Seu princípio se baseia na propriedade da vegetação saudável de refletir intensamente a radiação no infravermelho próximo (NIR), devido à estrutura celular de suas folhas, e de absorver a radiação no espectro do vermelho para a fotossíntese. Essa relação permite que o NDVI seja usado indiretamente em estudos hidrológicos para analisar a correlação entre a cobertura vegetal e eventos de precipitação extrema (Tan et al., 2015; Cui et al., 2019; Pei et al., 2021).

Para a delimitação de corpos d'água, o Normalized Difference Water Index (NDWI) é uma métrica de alta eficácia (McFeeters, 1996). Sua robustez se deve ao fato de que a água absorve fortemente a radiação NIR, enquanto reflete a luz verde, criando um forte contraste. Sua aplicação é vasta, sendo utilizado para monitorar

variações em rios com imagens Sentinel-2 (Abazaj, 2020), estimar áreas de inundação (Hazir et al., 2016) e avaliar a extensão de enchentes (Soltanian et al., 2019).

Para aumentar a precisão do NDBI, diversas melhorias foram propostas. Abordagens semiautomáticas, como a segmentação baseada em pixels, demonstraram ganhos de precisão ao diferenciar áreas urbanas de terras áridas (He et al., 2009). Além disso, variantes como o NDBI modificado (NDBIm) e o uso de imagens hiperespectrais têm mostrado resultados promissores ao superar limitações do índice original, como a confusão entre áreas construídas e solo exposto (Liu et al., 2014).

O NDBI também é frequentemente combinado com outros índices, como o NDVI e o NDWI, para fornecer uma análise mais abrangente das mudanças na cobertura do solo, e sua integração com dados de temperatura da superfície pode melhorar ainda mais a robustez das análises (Bhatti & Tripathi, 2014; Delgadillo-Herrera et al., 2019). Apesar de suas vantagens, o NDBI enfrenta desafios em ambientes complexos onde áreas construídas e solo exposto possuem respostas espectrais semelhantes, conforme observado na área de estudo, o que tem motivado pesquisas em métodos de normalização avançados (Santiago et al., 2020; Mfondoum et al., 2020).

O Bare Soil Index (BSI) é utilizado para a identificação de áreas de solo exposto, sendo um indicador essencial de processos como expansão urbana e desmatamento (Nguyen et al., 2021; Somanathan et al., 2024). Seu principal desafio é a semelhança espectral que pode ocorrer entre solos nus e áreas urbanas, o que pode resultar em classificações imprecisas (Rasul et al., 2018).

Adicionalmente, a integração do BSI com técnicas avançadas de aprendizado de máquina, como modelos de ensemble, tem se mostrado eficaz para aumentar a precisão do mapeamento de solos nus (Salas & Kumaran, 2023). O uso de imagens hiperespectrais e a combinação de múltiplos índices espectrais também têm ampliado a aplicabilidade do BSI em diferentes contextos ambientais, permitindo análises mais robustas e detalhadas (Vaudour et al., 2021). Resultados de estudos de caso, como o de Hashim et al. (2023) na cidade de Multan, Paquistão, exemplificam essa dinâmica. Utilizando índices espectrais como o NDBaI, os autores observaram uma conversão contínua de solo exposto e terras agrícolas em área construída ao longo de um período de 30 anos, um padrão de transformação recorrente em paisagens urbanas em desenvolvimento.

3.3.CLASSIFICADOR K-NEAREST NEIGHBORS (KNN)

Para traduzir os dados espectrais em mapas temáticos de LULC, uma variedade de classificadores de aprendizado de máquina tem sido aplicada com sucesso, especialmente com dados de alta resolução como os do Sentinel-2. Algoritmos como Support Vector Machine (SVM) e Random Forest (RF) têm demonstrado alta performance em estudos comparativos (Abdi, 2019). Dentro deste universo, o k-Nearest Neighbors (kNN), ou k-vizinho mais próximo, destaca-se como uma das abordagens não paramétricas mais antigas e robustas (Fix; Hodges, 1951). A essência do algoritmo consiste em identificar um conjunto de k amostras de treinamento que se encontram mais próximas de um pixel desconhecido, classificando-o com base na classe majoritária entre esses vizinhos (Zhang et al., 2023). Contudo, a precisão desse método pode ser impactada pela mistura espectral, especialmente em paisagens heterogêneas. Conforme aponta Abdi (2019), superfícies artificiais em áreas suburbanas frequentemente se mesclam com vegetação, resultando em pixels mistos que dificultam a distinção entre as classes e podem levar a erros na classificação. A distância entre os vizinhos geralmente é calculada utilizando a métrica euclidiana no espaço de características espectrais (Pan et al., 2015).

De forma mais aprofundada, o processo de estimação para um pixel p a ser classificado envolve o cálculo da sua distância espectral para cada pixel de amostra conhecido p_i (Franco-Lopes, 2001). Para cada pixel p, são selecionados os k vizinhos mais próximos, e a estimativa da classe é expressa como uma função ponderada desses vizinhos, onde os vizinhos mais próximos recebem um peso maior. Uma função frequentemente utilizada para ponderar as distâncias é dada pela equação 1:

$$w_{(p_i)p} = \frac{1}{d_{(p_i)p}^t} \sum_{j=1}^k \frac{1}{d_{(p_i)p}^t} \quad (1)$$

com $t=2$, a estimativa da variável m para o pixel p é então dada pela equação 2:

$$m_p = \sum_{i=1}^k w_{(p_i)p} m_{(p_i)} \quad (2)$$

Onde $m(p_i)$ é o valor da variável (classe) na amostra i correspondente ao pixel $p(i)$, que é o i -ésimo vizinho mais próximo no espaço espectral do pixel p (Franco-Lopes, 2001).

A eficácia do kNN para o mapeamento de LULC foi recentemente demonstrada por Lefulebe et al. (2023), que, ao utilizarem o classificador em imagens de alta resolução, obtiveram uma acurácia global superior a 98%, reforçando a validade do método para a criação de séries temporais de uso do solo. Embora eficaz, o kNN possui desafios conhecidos, como a sensibilidade a classes desbalanceadas, o que tem levado ao desenvolvimento de variações do algoritmo para otimizar seu desempenho em paisagens complexas (Zhang et al., 2019).

O potencial do kNN também foi demonstrado em diversos estudos de previsão de inundações (Xu et al., 2018; Ren et al., 2019). De acordo com Liu et al. (2021), o modelo kNN apresenta um desempenho mais robusto para a previsão de inundações durante períodos mais longos, e a principal razão para essa robustez reside em sua natureza não-paramétrica, que não assume uma distribuição estatística pré-definida para os dados, adaptando-se bem a sistemas ambientais complexos.

3.4.PROCESSO DE HIERARQUIA ANALÍTICA (AHP)

O Processo de Hierarquia Analítica (AHP), desenvolvido por Thomas Saaty, destaca-se como uma das principais e mais consolidadas metodologias multicritério para tomada de decisão (Saaty, 1990; Khaddari et al., 2023). De acordo com Dotto et al., (2023), a Técnica AHP possibilita a álgebra de mapas com base na ponderação de diferentes planos de informações cartográficas sendo atribuído uma hierarquia de importância dessas variáveis sobre um objetivo em comum. Diversos são os autores que têm utilizado o método de análise multicritério AHP para estudos de processos superficiais dentre eles (Bera et al., 2019). Sua notável eficácia reside na capacidade de transformar julgamentos de valor, tanto qualitativos quanto quantitativos, em prioridades numéricas. A relevância do AHP é amplamente reconhecida nas geociências, com uma vasta aplicação que se estende ao mapeamento de suscetibilidade a diversos desastres naturais, como inundações (Selvam e Antony Jebamalai, 2023; Bokhari et al., 2024), processos erosivos (Dotto et al., 2023) e análise de fragilidade ambiental (Weiss e Pippi, 2019).

A aplicação do AHP é estruturada em etapas sequenciais que garantem a lógica e a consistência da análise (Khaddari et al., 2023). O processo inicia-se pela

decomposição do problema em uma estrutura hierárquica, onde o objetivo principal é posicionado no topo, seguido pelos critérios (fatores) e subcritérios que o influenciam (Bokhari et al., 2024). Em seguida, os elementos de cada nível são submetidos a comparações par a par, uma etapa em que a importância relativa entre os critérios é julgada com base na Escala Fundamental de Saaty (Tabela 1). Esta escala atribui valores de 1 (importância igual) a 9 (importância absoluta) para consolidar as prioridades em uma matriz pareada (Saaty, 1990; Selvam e Antony Jebamalai, 2023).

Tabela 1 - Escala de ponderação de Saaty.

Índice de importância	Definição	Explicação
1	Equivalência de importância	Elementos com impacto idêntico no objetivo.
3	Ligeiramente importante	Um elemento é um pouco mais importante que o outro.
5	Muito mais importante	Um elemento é distintamente mais importante.
7	Predominantemente mais importante	Um elemento prepondera claramente.
9	Extremamente mais importante	Um elemento é inequivocamente o mais influente.
2, 4, 6, 8	Valores intermediários	Usados para expressar gradações de importância.

Fonte: Adaptado de Saaty (1987).

A partir da matriz de comparações, são calculados os autovetores, que correspondem aos pesos de prioridade normalizados para cada critério (Selvam e Antony Jebamalai, 2023). Um aspecto crucial do método é a verificação da consistência dos julgamentos, realizada pelo cálculo da Razão de Consistência (RC), que é obtida pela divisão do Índice de Consistência (IC) pelo Índice Randômico (IR) (Khaddari et al., 2023) (Tabela 2). Um valor de RC inferior a 0,1 é universalmente aceito como indicativo de uma consistência razoável nos julgamentos, conferindo confiabilidade ao processo decisório (Saaty, 1990; Khaddari et al., 2023).

Tabela 2 - Índice Randômico do AHP em função do tamanho da matriz.

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
0,00	0,00	0,58	0,90	1,12	1,24	1,32	1,41	1,45	1,49	1,51	1,48	1,56	1,57	1,59

Fonte: Saaty (1987)

Apesar de sua ampla aplicação e robustez, uma limitação inerente ao AHP é a subjetividade na etapa de comparação par a par, cujos julgamentos dependem da expertise do tomador de decisão (Bokhari et al., 2024). Contudo, o cálculo da Razão de Consistência funciona como um mecanismo de controle rigoroso para garantir a validade lógica e a consistência desses julgamentos, mitigando o viés e assegurando a fidedignidade do modelo (Bokhari et al., 2024).

De acordo com Madzík & Falát (2022), o uso do método AHP em pesquisas e aplicações práticas, é muito difundido. Em conexão com o crescimento intensivo do uso do AHP, a necessidade de captura de tendências atualizadas está se tornando cada vez mais importante (Madzík & Falát, 2022). O artigo de revisão publicado por estes autores se concentra numa revisão abrangente orientada por dados do uso do AHP, analisando uma grande quantidade de documentos Scopus. Comparado às revisões sistemáticas padrão, este estudo pode fornecer uma visão mais ampla do método AHP.

3.5.AVALIAÇÃO DE ACURÁCIA DE CLASSIFICADORES

A validação da acurácia de mapas de uso e cobertura do solo é uma etapa metodológica indispensável, que quantifica a concordância entre os resultados da classificação e os dados de referência (Olofsson et al., 2014). A ferramenta fundamental para esta avaliação é a matriz de confusão, que tabula o número de pixels classificados corretamente e os erros de comissão (inclusão incorreta em uma classe) e omissão (exclusão incorreta de uma classe) (Kusuma et al., 2023).


A partir da matriz de confusão, diversas métricas de desempenho são calculadas. A Acurácia Global é a métrica mais direta, representando a proporção de pixels corretamente classificados em relação ao total de amostras de validação (Lefulebe et al., 2023). Contudo, para uma avaliação mais robusta, o Índice Kappa é amplamente empregado na literatura. O Kappa oferece uma medida de concordância que corrige o alinhamento que poderia ocorrer meramente ao acaso, sendo um indicador mais fidedigno do desempenho do classificador (Andrade et al., 2024; Rabby et al., 2020). Em pesquisas que comparam a eficiência de diferentes algoritmos de aprendizado de máquina, o uso combinado da Acurácia Global e do Índice Kappa é uma prática padrão para uma avaliação rigorosa e completa (Pan et al., 2019; Kusuma et al., 2023).

4. METODOLOGIA

4.1.ÁREA DE ESTUDO

O município de Barreiros está localizado na Zona da Mata de Pernambuco, Brasil, e apresenta uma área de aproximadamente 234 km², com população superior a 40 mil habitantes (IBGE, 2022). Inserido na bacia hidrográfica do rio Una, o município é atravessado por este curso d'água, com nascente em Capoeiras a 900 metros de altitude, que percorre cerca de 255 km até desaguar no Oceano Atlântico, na divisa dos territórios de Barreiros e São José da Coroa Grande (APAC, 2013). A localização da área de estudo é ilustrada na Figura 1.


Figura 1 - Mapa da Área de Estudo.



Fonte: Elaborada pelo próprio autor (2025).

A região possui clima tropical úmido, classificado como As, segundo Köppen-Geiger (Alvares et al., 2013) e integra o bioma Mata Atlântica, com vegetação típica de floresta tropical, embora severamente fragmentada devido ao desmatamento e uso intensivo do solo para atividades agrícolas e urbanas. De acordo com o conjunto de dados de precipitação e temperatura obtidos pelo atlas climatológico desenvolvido pela Agência Pernambucana de Águas e Clima (APAC, 2023) a região de estudo possui uma normal climatológica (1991–2020) apresentado pela figura 2, é observado uma estação chuvosa definida entre março a agosto com chuvas acima da média de 156,8 mm e os demais meses secos abaixo da média, sua maior concentração se destaca no mês de junho onde são obtidos valores superiores a 330 mm, as temperaturas persistem elevadas entre outubro e abril superiores à média de 25,5°C tendo a máxima no mês de fevereiro com 26,7°C e mínima em julho com 23,9°C.

Figura 2 - Climograma da área de estudo, município de Barreiros/PE – Normais Climatológicas (1991-2020)



Fonte: APAC (2023).

Barreiros destaca-se por sua notável geodiversidade, composta por formações sedimentares da Bacia de Pernambuco e o embasamento cristalino neoproterozoico, elementos que conferem à região um valioso patrimônio geológico. Essa riqueza cria oportunidades significativas para o desenvolvimento de iniciativas de ecoturismo e conservação ambiental, promovendo o conhecimento das geociências e o uso sustentável dos recursos naturais. Além disso, o município agrega um patrimônio histórico, cultural e arqueológico de grande relevância, consolidando-se como um destino turístico atrativo, especialmente para o turismo de sol e praia, e atendendo a diferentes perfis de visitantes (Guimarães, 2016).

O município enfrentou eventos críticos de inundações, como os registrados em 2010 e 2017, que provocaram danos socioeconômicos significativos. Em junho de 2010, uma perturbação de onda de leste gerou chuvas intensas que levaram ao transbordamento dos rios Una e Mundaú, afetando diversas cidades na bacia desses rios. Esses eventos extremos são intensificados por desigualdades sociais e infraestrutura inadequada, que ampliam os riscos e a vulnerabilidade urbana (Lucena, 2016; Alves, 2022). Em Barreiros, esses eventos têm se tornado mais frequentes, tendo-se uma recorrência de 18 eventos de inundação entre os anos de 1989 a 2021, refletindo a tendência global de aumento de inundações em áreas urbanas (Alves, 2022).

Para enfrentar esses desafios, foi contemplado com projetos de infraestrutura urbana voltados à melhoria do saneamento básico e drenagem de águas pluviais. Desde 1989, o município está inserido no Projeto de Saneamento de Pernambuco, que foi reformulado em 2001 para contemplar medidas voltadas ao abastecimento de água e saneamento central. Além disso, a implementação de sistemas de previsão de enchentes, com integração de modelos hidrológicos e hidrodinâmicos, representou um avanço significativo na mitigação de desastres naturais na bacia do Rio Una. Apesar dos progressos, eventos extremos como os de 2010 ainda representam um risco considerável (Alves, 2017).

Combinando desafios climáticos, importância ambiental e potencial turístico, Barreiros se configura como uma área de estudo de alta relevância para análises sobre uso e ocupação do solo em contextos de vulnerabilidade socioambiental e para o planejamento territorial sustentável.

4.2. MATERIAIS

4.2.1. Dados Orbitais

A presente pesquisa contará com dados orbitais provenientes da missão Sentinel-2, um componente essencial do programa Copernicus da Comissão Europeia, que foi desenvolvida, operada e gerida por diversos estabelecimentos da European Space Agency (ESA). A missão é composta por uma constelação de dois satélites idênticos – Sentinel-2A e Sentinel-2B – que operam na mesma órbita terrestre, separados por 180° para assegurar uma cobertura ideal. Juntos, os satélites fornecem imagens de toda a superfície terrestre, grandes ilhas, águas interiores e

costeiras com uma frequência de revisita de cinco dias no Equador, oferecendo dados consistentes e de alta qualidade para uma ampla gama de aplicações (ESA, 2014).

O Sentinel-2 se destaca por suas aplicações em monitoramento ambiental, abrangendo áreas como agricultura, florestas, mapeamento de variáveis biofísicas, alterações no uso e cobertura da terra, monitoramento de águas costeiras e interiores, além de suporte a ações de mapeamento de riscos e desastres naturais. O Sentinel-2A foi lançado em 23 de junho de 2015, enquanto o Sentinel-2B foi lançado em 7 de março de 2017, marcando a consolidação dessa missão como uma ferramenta crucial para o estudo da superfície terrestre (ESA, 2015).

Para a investigação da dinâmica da cobertura do solo, optou-se por uma análise multitemporal que permitisse avaliar a resposta da paisagem nos anos subsequentes ao evento de inundação. Foram selecionadas três imagens multiespectrais do Sentinel-2: a primeira, do período da inundação, servindo como linha de base do impacto; as duas seguintes, de um e quatro anos após o evento, foram utilizadas para a análise da evolução da área de estudo. A estratégia de monitorar a condição de um território em diferentes fases pós-desastre é uma abordagem consistente com a literatura de sensoriamento remoto (Stoyanova, 2023; Farhadi et al., 2022). As principais características das imagens são apresentadas na Tabela 3.

Tabela 3 - Especificações das imagens Sentinel-2.

Missão/ Satélite	Nível de processamento	Tipo de Produto	Data de Aquisição	Informação adicional
Sentinel-2B	Level-2A	S2MSI2A	2017-06-27	Período inundação
Sentinel-2B	Level-2A	S2MSI2A	2018-06-22	Período pós-inundação
Sentinel-2B	Level-2A	S2MSI2A	2021-06-26	Período pós-inundação

Fonte: Elaboração pelo próprio autor (2025).

Cada satélite embarca um Multi-Spectral Instrument - MSI, com uma largura da faixa orbital de 290 km, que possui capacidade de capturar imagens desde o espectro visível até o infravermelho de onda curta, oferecendo imagens de alta resolução espacial em escala global e alta frequência de revisita. O MSI foi projetado para medir a radiância refletida da Terra através da atmosfera em 13 bandas espectrais e respectivas resoluções associadas (Tabela 4), que incluem:

- 4 bandas com resolução espacial de 10 m: *blue* (490 nm), *green* (560 nm), *red* (665 nm) e *near infrared* (842 nm);

- 6 bandas com resolução espacial de 20 m: quatro bandas específicas para caracterização de vegetação (705 nm, 740nm, 783 nm e 865 nm) e duas bandas SWIR (1610 nm e 2190 nm) para aplicações como detecção de neve/gelo/nuvens ou avaliação do estresse hídrico na vegetação;
- 3 bandas com resolução espacial de 60 m, principalmente para filtragem de nuvens e correções atmosféricas: 443 nm para aerossóis, 945 nm para vapor d'água e 1375 nm para *cirrus detection*.

Tabela 4 - Bandas e resoluções do MSI Sentinel-2.

Banda MSI	Resolução Espacial (m)	Sentinel-2A (S2A)		Sentinel-2B (S2B)	
		Comprimento de onda central (nm)	Largura da banda (nm)	Comprimento de onda central (nm)	Largura da banda (nm)
B1: Coastal Aerosol	60	443,9	27	442,3	45
B2: Blue	10	496,6	98	492,1	98
B3: Green	10	560,0	45	559	46
B4: Red	10	664,5	38	665	39
B5: Vegetation Red-Edge	20	703,9	19	703,8	20
B6: Vegetation Red-Edge	20	740,2	18	739,1	18
B7: Vegetation Red-Edge	20	782,5	28	779,7	28
B8: NIR	10	835,1	145	833	133
B8A: Vegetation Red Edge	20	864,8	33	864	32
B9: Water Vapor	60	945,0	26	943,2	27
B10: SWIR Cirrus	60	1373,5	75	1376,9	76
B11: SWIR	20	1613,7	143	1610,4	141
B12: SWIR	20	2202,4	242	2185,7	238

Fonte: ESA (2024).

4.2.2. Softwares e Ferramentas

O Quantum Geographic Information System (QGIS) será a principal ferramenta utilizada na pesquisa para o processamento e análise dos dados geoespaciais. Trata-se do software geoespacial livre mais popular do mundo, pertencente à Open Source Geospatial Foundation (OSGeo), amplamente reconhecido pela comunidade acadêmica e profissional por sua flexibilidade, robustez e crescente popularidade (Flenniken et al., 2020; Garcia-Alvarez et al., 2022; Rosas-Chavoya et al., 2022). Como uma plataforma de código aberto, o QGIS oferece um ambiente acessível para

a visualização, edição e análise de dados georreferenciados, funcionando como uma alternativa viável a pacotes de softwares proprietários de alto custo (Flenniken et al., 2020).

O software é um projeto de código aberto, impulsionado por uma comunidade global e voluntária de usuários e desenvolvedores que continuamente aprimoram suas funcionalidades (Flenniken et al., 2020; Rosas-Chavoya et al., 2022). Este modelo colaborativo reflete-se em sua crescente aceitação científica, com um aumento anual de 40,3% nas publicações relacionadas entre 2005 e 2020, estabelecendo sua relevância em diversas áreas, com destaque para as Ciências da Terra, Ciências Ambientais e planejamento urbano (Rosas-Chavoya et al., 2022; Flenniken et al., 2020).

Uma das maiores fortalezas do QGIS é sua capacidade de integrar e estender funcionalidades por meio de plugins (Rosas-Chavoya et al., 2022; Garcia-Alvarez et al., 2022). O software oferece uma interface unificada para muitos outros programas de geoprocessamento de código aberto, como SAGA GIS, GDAL e GRASS GIS, além de permitir uma poderosa integração com a linguagem R para análises estatísticas avançadas (Garcia-Alvarez et al., 2022; Congedo, 2021). Essa flexibilidade proporcionada pela integração facilita a manipulação de mapas, a automação de tarefas e a realização de análises complexas (Duarte et al., 2021).

Para a execução desta pesquisa, a integração do QGIS com a linguagem Python é um recurso central. O software permite estender suas funções por meio de uma API e de plugins escritos em Python, o que possibilita a criação de scripts para processar dados geoespaciais de forma eficiente e automatizada (Congedo, 2021). Essa capacidade de automação é fundamental para a execução de tarefas complexas como o cálculo dos índices espectrais em lote e o pré-processamento das imagens de satélite. Recentemente, a comunidade tem desenvolvido ativamente plugins que integram técnicas modernas, como aprendizado de máquina, diretamente na interface do QGIS para facilitar o mapeamento digital e outras análises de suscetibilidade (Pereira et al., 2022; Titti et al., 2022).

Outra ferramenta central para a pesquisa é o Google Colaboratory (Colab), um serviço de nuvem que oferece um ambiente de programação Python interativo por meio de Jupyter Notebooks (Tock, 2019). A plataforma é particularmente útil para a pesquisa em aprendizado de máquina e sensoriamento remoto, pois permite o acesso gratuito a uma infraestrutura de hardware de alta performance, incluindo

processadores do tipo CPU, GPU e TPU, além de armazenamento integrado ao Google Drive (Guntara, 2023). Esse acesso a unidades de processamento gráfico (GPUs) acelera drasticamente aplicações computacionais intensivas, como o treinamento de modelos de Deep Learning e a análise de grandes volumes de dados (Carneiro et al., 2018). Como contraponto, a versão gratuita da plataforma apresenta um desafio prático que funciona como um alerta: as sessões podem ser encerradas após longos períodos de inatividade, exigindo que o ambiente, as bibliotecas e os dados sejam recarregados para a continuidade do trabalho (Tock, 2019).

A utilidade da plataforma no campo do aprendizado de máquina é ampliada pelo fato de que seu ambiente já vem configurado com as principais bibliotecas científicas, como Keras, TensorFlow, NumPy e Pandas, dispensando complexos processos de instalação (Guntara, 2023). Essa capacidade de processar grandes conjuntos de dados de sensoriamento remoto diretamente na nuvem é uma vantagem significativa para pesquisadores (Johary et al., 2023). Um exemplo prático de sua eficácia foi demonstrado por Zhang e Tang (2018), que empregaram o Colab na extração de áreas urbanas a partir de imagens Landsat 8 com redes neurais convolucionais (CNN), alcançando alta precisão.


Em termos de desempenho, o Colab se destaca na execução de tarefas de classificação a partir de dados de sensoriamento remoto. Bantchina e Gündoğdu (2024) demonstraram que modelos de aprendizado de máquina aplicados a dados do Sentinel-2 no Colab foram bem-sucedidos na classificação de tipos de culturas com precisão superior a 95%. Além da capacidade computacional, a plataforma facilita a colaboração e a reprodutibilidade da pesquisa, pois os notebooks, que contêm código, textos explicativos e resultados, podem ser facilmente compartilhados, eliminando barreiras de instalação de software e diferenças entre plataformas (Tock, 2019; Johary et al., 2023).

A literatura estabelece, portanto, os papéis complementares de plataformas como o Colab e o QGIS. O ambiente Colab, com sua capacidade de processamento em nuvem e automação via Python, é ideal para as etapas computacionalmente intensivas, como o treinamento de modelos e o processamento em lote de grandes volumes de imagens (Johary et al., 2023; Guntara, 2023). O QGIS, por sua vez, consolida-se como a ferramenta para as fases subsequentes, oferecendo um robusto conjunto de funcionalidades para análises espaciais detalhadas, pós-processamento,

avaliação de acurácia e a elaboração da cartografia final (Congedo, 2021; Garcia-Alvarez et al., 2022).

4.3. PROCEDIMENTOS METODOLÓGICOS

O procedimento metodológico foi estruturado em três grandes etapas que sintetizam o fluxo lógico e integrado da pesquisa: I) Aquisição de Dados, II) Processamento dos Dados e III) Análises e Resultados (Figura 3). Essas etapas refletem, de forma sistemática, o percurso da pesquisa, desde a coleta das informações iniciais até a geração e interpretação dos resultados. A abordagem busca organizar os processos de entrada, transformação e saída dos dados de maneira clara, objetiva e alinhada aos objetivos do estudo.



Fonte: Elaborada pelo próprio autor (2025).

Na primeira etapa, aquisição de dados, foram realizadas as atividades fundamentais para compor a base da pesquisa. Conforme detalhado no fluxograma (Figura 3), essa fase contemplou a delimitação da área de estudo, a seleção e aquisição das imagens do satélite Sentinel-2 para os anos de 2017, 2018 e 2021, e a obtenção de dados climatológicos secundários, especificamente a normal climatológica de precipitação e temperatura da Agência Pernambucana de Águas e Clima (APAC). As imagens foram selecionadas com base em critérios técnicos, como

baixa cobertura de nuvens e pertinência da data de aquisição para a análise das dinâmicas de uso e ocupação do solo.

A segunda etapa, processamento, constituiu o núcleo técnico da metodologia, centrada no geoprocessamento para a transformação dos dados brutos em informações organizadas e interpretáveis. Inicialmente, foram realizadas etapas de pré-processamento das imagens, incluindo correções atmosféricas, para garantir a precisão dos dados. Em seguida, foram calculados os índices espectrais NDVI, MNDWI, NDBI e BSI. Para o mapeamento de suscetibilidade, foram preparados e ponderados os fatores condicionantes (hipsometria, uso e cobertura do solo, densidade urbana, pedologia e NDVI) utilizando o Processo de Hierarquia Analítica (AHP). Adicionalmente, ocorreu o treinamento do modelo de classificação supervisionada kNN. Essa etapa foi conduzida com rigor técnico, utilizando amostras de treinamento e validação selecionadas por meio de fotointerpretação visual de imagens de satélite de alta resolução, basemap do google, uma prática consolidada para gerar dados de referência sem a necessidade de visitas a campo.

A segunda etapa, processamento, constituiu o núcleo técnico da metodologia, centrada no geoprocessamento para a transformação dos dados brutos em informações organizadas e interpretáveis. Para garantir a precisão dos dados, foram utilizadas imagens Sentinel-2 de Nível de Processamento 2A (Level-2A), que já são disponibilizadas com a correção atmosférica aplicada, fornecendo valores de reflectância de superfície. Este processamento é tipicamente realizado com o algoritmo Sen2Cor, o processador padrão da ESA para esta finalidade (Abdi, 2019). Em seguida, foram calculados os índices espectrais NDVI, MNDWI, NDBI e BSI.

Para o mapeamento de suscetibilidade, foram preparados e ponderados os fatores condicionantes (hipsometria, uso e cobertura do solo, densidade urbana, pedologia e NDVI) utilizando o AHP. Adicionalmente, ocorreu o treinamento do modelo de classificação supervisionada kNN. Essa etapa foi conduzida com rigor técnico, utilizando amostras de treinamento e validação selecionadas por meio da fotointerpretação de imagens de satélite de maior resolução espacial, uma abordagem padrão para obter dados de referência de alta qualidade para a validação de mapas temáticos (Garcia-Alvarez et al., 2022).

Na terceira etapa, análises e resultados, os dados processados foram utilizados para análises espaço-temporais e avaliação da precisão do modelo kNN. Os mapas temáticos gerados foram submetidos a validações quantitativas, utilizando a matriz de

confusão para comparar as classificações do modelo com as amostras de referência. A partir dessa matriz, métricas como Acurácia Global e o Índice Kappa foram calculadas para avaliar o desempenho do modelo. O uso da matriz de confusão e de métricas derivadas, como o Kappa, é uma prática padrão e amplamente recomendada na literatura para a avaliação rigorosa da acurácia de mapas de uso e cobertura do solo (Olofsson et al., 2014; Garcia-Alvarez et al., 2022).

Após a validação, os resultados foram explorados em análises espaço-temporais detalhadas. O cálculo dos índices espectrais (NDVI, MNDWI, NDBI e BSI) e a geração dos mapas temáticos foram implementados por meio de um fluxo de trabalho computacional desenvolvido em Python. O processamento foi executado na plataforma em nuvem Google Colaboratory, um ambiente reconhecido por sua capacidade de lidar com grandes volumes de dados de sensoriamento remoto (Johary et al., 2023). Esta abordagem permitiu a identificação de padrões e tendências na dinâmica do uso e ocupação do solo, bem como mudanças significativas na área de estudo ao longo do tempo.

4.3.1. Índices Espectrais

Para a caracterização quantitativa da cobertura do solo, a metodologia empregou o cálculo de quatro índices espectrais derivados das bandas multiespectrais das imagens Sentinel-2. A avaliação da presença e vigor da vegetação foi realizada por meio do Índice de Vegetação por Diferença Normalizada (NDVI), que se baseia na relação entre a alta reflectância da vegetação saudável no infravermelho próximo (NIR) e a absorção pela clorofila na banda do vermelho (RED) (Rouse et al., 1974), disposto na equação 3.

$$\text{NDVI} = (\text{NIR} - \text{RED}) / (\text{NIR} + \text{RED}) \quad (3)$$

Os valores de NDVI resultantes foram posteriormente classificados em cinco classes temáticas, adotando-se os limiares detalhados na Tabela 5, que foram adaptados de uma metodologia consolidada na literatura (Bezerra et al., 2018).

Tabela 5 - Intervalos de NDVI para uso e ocupação do solo.

Classes Temáticas	Intervalo NDVI
Água	< 0,00
Solo Exposto	0,00 – 0,19
Vegetação Baixa	0,20 – 0,39
Vegetação Média	0,40 – 0,60
Vegetação Densa	> 0,60

Fonte: Bezerra et al. (2018).

Para a delimitação de feições hídricas, foi utilizado o Índice de Água por Diferença Normalizada Modificado (MNDWI), cuja escolha se justifica por sua maior robustez em paisagens urbanas. Diferentemente do NDWI tradicional, o MNDWI substitui a banda NIR pela SWIR, o que, segundo Xu (2006), otimiza a extração de água ao suprimir eficazmente o ruído espectral de áreas construídas, que apresentam reflectância semelhante à da água no NIR. O cálculo do índice, que apresenta maior absorção pela água e menor confusão com edificações, é regido pela equação 4.

$$\text{MNDWI} = (\text{GREEN} - \text{SWIR}) / (\text{GREEN} + \text{SWIR}) \quad (4)$$

Os resultados foram categorizados com base em limiares estabelecidos na literatura, onde valores positivos indicam a presença de água (Ji; Peters, 2003; Xu, 2006).

O mapeamento de áreas construídas e superfícies impermeáveis foi realizado com o Índice de Diferença Normalizada de Áreas Construídas (NDBI), que explora a maior reflectância das áreas urbanas na banda SWIR em comparação com a banda NIR (Zha et al., 2003), regido pela equação 5.

$$\text{NDBI} = (\text{SWIR} - \text{NIR}) / (\text{SWIR} + \text{NIR}) \quad (5)$$

A fórmula se baseia na diferença entre as bandas SWIR e NIR, considerando que áreas construídas tendem a ter maior reflectância no SWIR do que no NIR, enquanto áreas vegetadas apresentam o comportamento oposto. Esse contraste espectral permite ao NDBI identificar áreas urbanas de maneira eficiente.

A identificação de áreas de solo exposto foi efetuada por meio do cálculo do Índice de Solo Exposto (BSI), que utiliza uma combinação de bandas espectrais para destacar a resposta de solos nus em contraste com outras coberturas do solo (Nguyen et al., 2021), elencado na equação 6.

$$BSI = \frac{(Banda\ SWIR2 + Banda\ RED) - (Banda\ NIR + Banda\ BLUE)}{(Banda\ SWIR2 + Banda\ RED) + (Banda\ NIR + Banda\ BLUE)} \quad (6)$$

As bandas NIR, RED, BLUE e GREEN, correspondem à reflectância nas bandas do infravermelho próximo, vermelho, azul e verde, respectivamente. A combinação dessas bandas permite destacar as características espectrais dos solos expostos, tornando o BSI eficaz para o mapeamento de áreas de solo nu em imagens de satélite, como as obtidas pelos sensores Landsat 8 e Sentinel-2 (Nguyen et al., 2021; Salas & Kumaran, 2023).

A análise multitemporal desta pesquisa foi estruturada a partir de uma seleção criteriosa das datas das imagens Sentinel-2. Adotou-se o mês de junho como referência temporal para todas as aquisições, pois, sendo o pico da estação chuvosa segundo a normal climatológica (Figura 2), sua padronização minimiza os efeitos da sazonalidade da vegetação na análise comparativa. A seleção dos anos, por sua vez, visou abranger a diversidade de condições que impactaram a área de estudo. Foram escolhidos os anos de 2017, 2018 e 2021 para representar, respectivamente, três cenários hidrológicos e climáticos distintos: um evento de inundação (Alves et al., 2024), um período subsequente a uma seca (Lima et al., 2022) e um ano de chuvas irregulares associadas ao fenômeno La Niña (Colussi et al., 2023).

4.3.2. Classificador k-Nearest Neighbors (kNN)

Para a classificação supervisionada do uso e cobertura do solo (LULC), a metodologia empregou o algoritmo de aprendizado de máquina k-Nearest Neighbors (kNN). A escolha deste classificador se baseia em sua robustez e eficácia demonstrada em estudos recentes de mapeamento de LULC com dados de sensoriamento remoto (Lefulebe et al., 2023). A implementação foi realizada em um ambiente de programação Python, utilizando bibliotecas de computação científica como a Scikit-Learn, o que permitiu um controle preciso sobre a modelagem.

O processo de classificação seguiu uma abordagem estruturada, iniciando-se com a divisão do conjunto de amostras em 70% para treinamento e 30% para validação do modelo, uma proporção comumente utilizada para garantir a independência na avaliação do desempenho (Kusuma et al., 2023). A métrica de distância euclidiana foi o critério utilizado para determinar a vizinhança mais próxima para a classificação dos pixels, com base em suas características espectrais no espaço de atributos (Ranjam & Singh, 2019).

Para otimizar a performance do classificador, foi realizada a sintonia do hiperparâmetro k (número de vizinhos), que é um passo crítico para o desempenho do kNN (Kusuma et al., 2023). Utilizou-se a abordagem GridSearchCV, uma técnica padrão para a busca exaustiva dos melhores parâmetros de um modelo por meio de validação cruzada (Pedregosa et al., 2011). Esta rotina foi implementada em Python e executada na plataforma Google Colaboratory, onde foram avaliados valores de k no intervalo de 1 a 10. A análise revelou que o valor de k que maximizava a acurácia variou a cada ano, evidenciando que a complexidade espectral da paisagem não é estática e que o modelo requer uma recalibração para cada marco em estudos multitemporais, uma observação pertinente para futuras pesquisas.

A análise da dinâmica da paisagem foi conduzida por meio de uma análise de mudanças pós-classificação, uma abordagem consolidada para estudos multitemporais (Hashim et al., 2023). Os mapas de LULC classificados para os diferentes períodos foram comparados para identificar e quantificar as transições entre as classes, como a conversão de vegetação para área urbana, ilustrando os efeitos da ocupação do solo (Lefulebe et al., 2023).

A avaliação da acurácia dos mapas gerados é uma etapa crítica e seguiu as boas práticas recomendadas para a validação de mapas temáticos (Olofsson et al., 2014). Para cada classificação anual, foi gerada uma matriz de confusão a partir do conjunto de amostras de validação, permitindo o cálculo das métricas de Acurácia Global e do Coeficiente Kappa para avaliar o desempenho geral do classificador (Garcia-Alvarez et al., 2022). O desempenho do kNN é reconhecidamente competitivo em relação a outros métodos de aprendizado de máquina, como Random Forest e Support Vector Machine (SVM), para a classificação de LULC a partir de dados Sentinel-2 (Abdi, 2019; Kusuma et al., 2023).

4.3.2.1. Preparação das amostras de treinamento e validação

A performance de um classificador supervisionado como o kNN depende diretamente da qualidade e representatividade dos conjuntos de amostras utilizados para treinamento e validação do modelo (Lefulebe et al., 2023). Para esta pesquisa, as amostras de referência para as quatro classes de uso do solo (água, solo exposto, área urbana e vegetação) foram obtidas por meio de fotointerpretação de imagens de satélite de maior resolução espacial, uma abordagem padrão para gerar dados de referência de alta qualidade (Garcia-Alvarez et al., 2022).

Para garantir a consistência e a comparabilidade dos resultados ao longo do tempo, o processo de amostragem foi padronizado anualmente. Para cada uma das quatro classes, foram selecionados 10 polígonos de amostra (regiões de interesse) com área de 20x20 metros. A partir desses polígonos, foram extraídos os pixels correspondentes das imagens Sentinel-2, resultando em um conjunto de dados de 40 pixels por classe, totalizando 160 pixels para cada ano analisado. Esta abordagem resultou em um conjunto de dados balanceado, o que é um pré-requisito importante para evitar viés no treinamento de classificadores de aprendizado de máquina (Kusuma et al., 2023). A Tabela 6 detalha a distribuição final das amostras.

Tabela 6 - Distribuição de amostras de treinamento e validação por classe e ano (2017-2021).

Classe	Nº de amostras	Nº de pixels (2017)	Nº de pixels (2018)	Nº de pixels (2021)
Água	10	40	40	40
Solo exposto	10	40	40	40
Área urbana	10	40	40	40
Vegetação	10	40	40	40

Fonte: Elaborada pelo próprio autor (2025).

4.3.3. Validação da Acurácia da classificação

A validação da acurácia dos mapas de LULC gerados é uma etapa metodológica indispensável para quantificar a performance do classificador (Olofsson et al., 2014). Para tal, foi utilizada uma matriz de confusão, que tabula os acertos e erros da classificação em relação a um conjunto de amostras de validação independentes (Garcia-Alvarez et al., 2022). A partir desta matriz, e por meio de

funções da biblioteca Scikit-Learn no ambiente Python, foram calculadas as seguintes métricas de desempenho

- Acurácia Global: Representa a proporção de amostras totais que foram classificadas corretamente (Lefulebe et al., 2023).
- Coeficiente Kappa: Uma métrica de concordância que corrige o acerto que poderia ocorrer meramente ao acaso, sendo um indicador mais robusto do desempenho do classificador (Kusuma et al., 2023).
- Precision (Precisão): Mede a proporção de predições positivas que foram corretas. Em LULC, mede a acurácia para cada classe em relação às predições do modelo (Kusuma et al., 2023).
- Recall (Sensibilidade): Mede a proporção de amostras positivas reais que foram corretamente identificadas pelo modelo (Kusuma et al., 2023).
- F1-Score: Corresponde à média harmônica entre Precision e Recall, fornecendo uma medida única e equilibrada do desempenho para cada classe (Kusuma et al., 2023).

4.3.4. Processo de Hierarquia Analítica (AHP) para mapeamento de Suscetibilidade

Para a elaboração do mapa de suscetibilidade a inundações, foi empregado o método de análise multicritério Processo de Hierarquia Analítica (AHP). A escolha desta abordagem é justificada por sua ampla aplicação e eficácia na modelagem de riscos ambientais em geociências, permitindo a integração de diferentes fatores geográficos em uma análise unificada (Khaddari et al., 2023; Selvam e Antony Jebamalai, 2023).

A modelagem da suscetibilidade a inundações foi estruturada a partir de cinco fatores condicionantes, cuja seleção e importância são validadas por um robusto corpo de pesquisas que aplicam o método AHP. Com base nisso, foram selecionados os seguintes fatores: Hipsometria, Uso e Cobertura do Solo, NDVI, Densidade Urbana e Pedologia. A escolha deste conjunto de fatores baseia-se em sua reconhecida e recorrente influência na dinâmica hídrica e nos processos de escoamento superficial, sendo um conjunto de variáveis frequentemente utilizado e validado em estudos análogos (Weiss e Pippi, 2019; Selvam e Antony Jebamalai, 2023; Bokhari et al., 2024; Lima, 2024).

- **Hipsometria:** A altitude do terreno foi extraída do Modelo Digital de Terreno (MDT) do projeto TOPODATA. A camada foi reclassificada, atribuindo-se maior suscetibilidade às áreas de menor altitude, que são naturalmente mais propensas à acumulação de água (Khaddari et al., 2023).
- **Uso e Cobertura do Solo:** Foi utilizado o mapa de LULC para o ano de 2021, o mais recente gerado nesta dissertação. As classes foram reclassificadas, com maior peso de suscetibilidade para superfícies impermeáveis (áreas urbanas) e menor para áreas com vegetação densa (Selvam e Antony Jebamalai, 2023).
- **NDVI:** O mapa de NDVI de 2021, também gerado nesta pesquisa, foi usado como um indicador da densidade vegetal. A camada foi normalizada de forma inversa, onde valores baixos de NDVI (pouca vegetação) receberam maior peso de suscetibilidade (Bokhari et al., 2024).
- **Densidade Urbana:** A concentração de edificações foi estimada a partir de um shapefile de setores censitários urbanos do Instituto Brasileiro de Geografia e Estatística (IBGE). Foram extraídos os centroides e calculada a densidade. Zonas de alta densidade urbana foram associadas a maior risco.
- **Pedologia:** As classes de solo foram obtidas a partir da base de dados da EMBRAPA sobre a distribuição espacial dos solos em Pernambuco. Os tipos de solo foram reclassificados com base em sua permeabilidade, com solos de baixa capacidade de infiltração (argilosos) recebendo maior peso de suscetibilidade (Weiss e Pippi, 2019).

Para garantir a comparabilidade entre os fatores, que possuem diferentes unidades e escalas de medida, cada camada foi reclassificada e normalizada em uma escala adimensional de 0 (menor suscetibilidade) a 1 (maior suscetibilidade). Este é um procedimento padrão em análises multicritério baseadas em SIG para padronizar os dados de entrada (Khaddari et al., 2023). A lógica hierárquica adotada para a normalização dos fatores, embora com intervalos ajustados para a realidade de Barreiros-PE, encontra forte precedente na literatura. Em conformidade com estudos análogos, atribuíram-se os maiores valores de suscetibilidade a classes como áreas de baixa altitude (Lima, 2022; Khaddari et al., 2023), superfícies impermeabilizadas como "Área Urbana" (Weiss e Pippi, 2019; Lima, 2024), e solos de baixa

permeabilidade como os Gleissolos (Lima, 2024). Os valores e intervalos normalizados para cada fator foram:

- Hipsometria:
 - 75m: 0,0
 - 60m: 0,25
 - 45m: 0,50
 - 30m: 0,75
 - <30m: 1,00
- Uso e Cobertura do Solo:
 - Vegetação: 0,1
 - Solo Exposto: 0,4
 - Área Urbana: 0,7
 - Água: 1,0
- NDVI: É um produto normalizado.
- Densidade Urbana: Produto derivado do adensamento de pontos, variando em um intervalo de 0,03 a 6,67 no raster. A normalização foi proporcional aos intervalos de valores máximo (1,0 normalizado) e mínimo (0,0 normalizado).
- Pedologia:
 - Latossolo Amarelo: 0,2
 - Argissolo Amarelo: 0,6
 - Luvisolo Crômico: 0,7
 - Gleissolo Háplico: 0,9

O processo metodológico seguiu as etapas canônicas do método: 1) Estruturação Hierárquica do problema; 2) Atribuição de Pesos por meio de uma matriz de comparação par a par; 3) Cálculo da Razão de Consistência (RC), que deveria ser inferior a 0,1 para validar os julgamentos (Saaty, 1990); e 4) Síntese e Agregação do

mapa final (Ms) por meio da Álgebra de Mapas, aplicando uma combinação linear ponderada (Equação 7):

$$Ms = (\omega H * H) + (\omega Us * Us) + (\omega DU * DU) + (\omega P * P) + (\omega ND * ND) \quad (7)$$

Onde: Ms = Mapa de suscetibilidade a inundações e alagamentos

H = Hipsometria

Us = Uso do solo

DU = Densidade urbana

P = Pedologia

ND = NDVI

ω = Peso atribuído ao fator respectivo, obtido por meio do AHP

A flexibilidade do AHP permite sua aplicação tanto de forma isolada quanto em conjunto com outras técnicas. Existem versões simplificadas, como o AHP-express, que agilizam o processo decisório, como apontam Tavana et al. (2021), Leal (2019) e Darko et al. (2019). Além disso, a implementação do método é facilitada pela disponibilidade de ferramentas e softwares online, conforme observado por Goepel (2018).

5. RESULTADOS E DISCUSSÃO

Esta seção apresentará os resultados obtidos a partir do processamento e análise dos dados de SR, incluindo a aplicação dos índices espectrais e da técnica de aprendizado de máquina (kNN) e o AHP. A apresentação será organizada para ilustrar o comportamento espaço-temporal da cobertura e uso do solo na área de estudo, a eficácia do modelo de classificação e a identificação de áreas suscetíveis a inundações.

5.1. ANÁLISE DOS ÍNDICES ESPECTRAIS E CARACTERIZAÇÃO DA COBERTURA DO SOLO


Esta subseção detalha a análise dos índices espectrais NDVI, MNDWI, NDBI e BSI, calculados a partir da imagem Sentinel-2. O propósito desta análise é a caracterização da cobertura do solo no município de Barreiros/PE para o referido marco temporal. A interpretação quantitativa dos resultados baseia-se nos limiares de classificação definidos na metodologia, estabelecendo a linha de base para a subsequente análise multitemporal.

5.1.1. Distribuição espacial dos Índices Espectrais – 2017

Esta subseção detalha a análise dos índices espectrais calculados a partir da imagem Sentinel-2 de 27 de junho de 2017. O propósito desta análise é a caracterização da cobertura do solo no município de Barreiros/PE para o referido marco temporal, que serve como linha de base para a subsequente análise multitemporal. A interpretação quantitativa dos resultados baseia-se nos limiares de classificação definidos na metodologia.

A análise dos mapas e histogramas para 27 de junho de 2017 revela uma paisagem com predominância de cobertura natural, mas com uma clara influência antrópica ao longo do vale do Rio Una. O mapa do Índice de Vegetação por Diferença Normalizada (NDVI) (Figura 4) ilustra a dominância da biomassa vegetal.


Figura 4 - Mapa do NDVI em Barreiros/PE para o ano de 2017



Fonte: Elaborada pelo próprio autor (2025).

O histograma do NDVI (Figura 5) confirma essa heterogeneidade com um comportamento multimodal, destacando-se um pico em valores negativos (entre -0,15 e -0,25), consistente com a resposta espectral de corpos d'água (Hashim et al., 2023), e dois picos em valores positivos (em torno de 0,2 a 0,6), que refletem a dicotomia entre vegetação de baixo e alto vigor (Goward et al., 1991; Bezerra et al., 2018).


Figura 5 - Histograma do NDVI – 2017.



Fonte: Elaborada pelo próprio autor (2025).

O mapa do Índice de Água por Diferença Normalizada Modificado (MNDWI) (Figura 6) permite a delimitação precisa dos corpos d'água. Valores positivos são visíveis no Rio Una, indicando a presença de água aberta, uma interpretação consistente com a metodologia do índice (Xu, 2006).


Figura 6 - Mapa do MNDWI em Barreiros/PE para o ano de 2017.



Fonte: Elaborada pelo próprio autor (2025).

O histograma (Figura 7) mostra um pico dominante em valores negativos, confirmando a predominância de superfícies terrestres. O valor modal em torno de -0,40, por exemplo, é característico de alvos onde a reflectância na banda do infravermelho de ondas curtas (SWIR) é significativamente superior à da banda verde, como é o caso da vegetação e do solo exposto. Contudo, o pico secundário em valores positivos (em torno de 0,1 a 0,2) é notável e representa a assinatura espectral das feições hídricas, que o MNDWI realça enquanto suprime o ruído de outras superfícies, como áreas construídas (Du et al., 2016; Xu, 2006). Valores positivos mais elevados geralmente indicam lâminas d'água mais abertas e com menor turbidez, sendo este um padrão de detecção consistente em estudos que utilizam o índice (Hashim et al., 2023).


Figura 7 - Histograma do MNDWI - 2017.



Fonte: Elaborada pelo próprio autor (2025).

O mapa do Índice de Diferença Normalizada de Áreas Construídas (NDBI) (Figura 8) é fundamental para identificar a mancha urbana. A interpretação baseia-se no princípio de que valores positivos indicam áreas construídas, enquanto os negativos correspondem a vegetação e água (Hashim et al., 2023; Zha et al., 2003). As maiores concentrações de valores positivos ocorrem na porção central, seguindo o curso do rio.


Figura 8 - Mapa do NDBI em Barreiros/PE para o ano de 2017.



Fonte: Elaborada pelo próprio autor (2025).

O histograma (Figura 9) corrobora esta análise, com um pico principal em valores negativos (entre -0,1 e -0,05), indicando que as áreas não construídas são predominantes. A assimetria positiva da curva, com uma cauda que se estende para valores positivos, representa a presença das áreas edificadas, um padrão esperado em paisagens mistas (Zha et al., 2003). A curva de distribuição apresenta um pico principal concentrado em valores negativos (aproximadamente entre -0,1 e -0,05), indicando a predominância de áreas não construídas, como vegetação e corpos d'água, o que é consistente com a literatura (Hashim et al., 2023).

Figura 9 - Histograma do NDBI - 2017.



Fonte: Elaborada pelo próprio autor (2025).

O mapa do Índice de Solo Exposto (BSI) (Figura 10) evidencia a distribuição de superfícies com solo nu, cujos valores mais elevados indicam áreas de agricultura ou pastagens degradadas (Nguyen et al., 2021).


Figura 10 - Mapa do BSI em Barreiros/PE para o ano de 2017.



Fonte: Elaborada pelo próprio autor (2025).

O histograma do BSI (Figura 11) apresenta um comportamento marcadamente bimodal, com um pico em valores negativos (em torno de -0,2), correspondente a áreas com cobertura consolidada (vegetação e água), e um segundo pico em valores positivos (próximo a 0,1), representando as superfícies de solo exposto. Este segundo pico pode também incluir a resposta de áreas urbanizadas, devido à conhecida semelhança espectral entre essas feições, um desafio metodológico documentado na literatura (Rasul et al., 2018).

Figura 11 - Histograma do BSI - 2017.



Fonte: Elaborada pelo próprio autor (2025).

5.1.2. Estatísticas descritivas e distribuição percentual dos Índices Espectrais - 2017

A análise quantitativa dos índices espectrais para a imagem de 27 de junho de 2017 permite caracterizar a paisagem de Barreiros neste marco temporal, que foi associado a eventos de chuvas intensas na região (Alves et al., 2024). As estatísticas descritivas (Tabela 7) e a distribuição percentual dos pixels por classes de índice (Tabela 8) fornecem a base para esta análise.

Tabela 7 - Estatísticas descritivas dos Índices Espectrais – 2017.

Índice	Mínimo	Máximo	Média	Mediana	Desvio Padrão	Assimetria	Curtose
NDVI	-0,2631	0,7381	0,3428	0,3643	0,2102	-0,6105	-0,0425
MNDWI	-1,0000	0,2915	-0,3036	-0,3228	0,1297	1,4509	9,1975
NDBI	-0,4388	1,0000	-0,0499	-0,0595	0,1615	1,1553	6,1013
BSI	-0,4901	1,0000	-0,0976	-0,0948	0,1691	0,9999	5,9086

Fonte: Elaborada pelo próprio autor (2025).

Tabela 8 - Distribuição percentual dos pixels por intervalo de valores dos Índices Espectrais - 2017.

Índice	Intervalo	Percentual (%)
NDVI	< 0,0	4,87
NDVI	0 a < 0,2	21,93
NDVI	0,2 a < 0,4	28,15
NDVI	0,4 a < 0,6	36,07
NDVI	>= 0,6	8,98
MNDWI	< 0,00	95,90
MNDWI	0,0 a < 0,2	2,35
MNDWI	>= 0,2	1,75
NDBI	< 0,00	61,98
NDBI	0,0 a < 0,06	11,72
NDBI	>= 0,06	26,30
BSI	< 0,00	66,49
BSI	0,0 a < 0,08	19,95
BSI	>= 0,08	13,56

Fonte: Elaborada pelo próprio autor (2025).

A análise quantitativa dos índices para 2017 revela uma paisagem predominantemente natural, mas já com uma clara marca da ocupação antrópica. O NDVI confirma a dominância da cobertura vegetal, com as classes de vegetação (moderada, densa e muito densa) somando mais de 73% da área total. A média do índice (0,3428) e a assimetria negativa (-0,6105) indicam uma paisagem com vegetação vigorosa, consistente com a data da imagem de 27/06/2017, um período chuvoso na região. Esse cenário é esperado para uma área inserida no bioma da Mata Atlântica e consistente com a literatura, que associa valores elevados de NDVI a uma vegetação saudável e densa (Hashim et al., 2023).

O dado mais relevante do MNDWI é a presença de 4,10% da área coberta por água (somando as classes de água rasa e aberta). Embora seja um percentual pequeno em relação ao total, ele é significativo por refletir o estado hidrológico de um ano marcado por inundações, capturando a extensão do Rio Una e de áreas alagadas que são cruciais para a análise de risco (Alves et al., 2024). A alta curtose (9,1975)

demonstra que, embora a maior parte da paisagem seja terrestre (mediana de -0,3228), existe uma cauda de valores positivos bem definida e relevante.

A análise do NDBI fornece a linha de base da mancha urbana, revelando que as “áreas construídas” ($\text{NDBI} \geq 0,06$) já representavam 26,30% do território em 2017. Este percentual substancial indica um núcleo urbano já consolidado. Somam-se a isso 11,72% de “áreas de transição / urbana de baixa densidade” ($0,0 < \text{NDBI} < 0,06$), que, juntamente com a assimetria positiva do índice (1,1553), funcionam como importantes indicadores das zonas de expansão e de transição urbano-rural, frequentemente as próximas a serem convertidas para uso urbano, uma dinâmica documentada em outras cidades em desenvolvimento (Hashim et al., 2023; Lefulebe et al., 2023).


Finalmente, a análise do BSI detalha as superfícies não vegetadas. A classe “solo exposto”, mais bem definida no intervalo entre 0,0 e 0,08, representava 19,95% da área, indicando a presença de superfícies desprovidas de vegetação. De forma complementar, a classe “transição/misto” ($\text{BSI} \geq 0,08$), com 13,56%, realça um desafio metodológico importante: é nesta faixa de valores mais elevados que a resposta espectral do solo pode se confundir com a de áreas construídas. Essa sobreposição é uma limitação conhecida do índice em paisagens heterogêneas (Rasul et al., 2018). Independentemente da distinção, a predominância de valores negativos (66,49%), refletida na média de -0,0976, reforça o cenário de uma paisagem com vegetação e umidade consolidadas para este marco temporal.

5.1.3. Distribuição espacial dos Índices Espectrais – 2018

A análise da distribuição espacial dos índices espectrais para a imagem de 22 de junho de 2018 oferece um primeiro retrato da resposta da paisagem no período subsequente ao cenário de alta pluviosidade de 2017. A comparação com o ano anterior permite, portanto, identificar as mudanças de curto prazo na cobertura do solo e a dinâmica inicial de resposta do ambiente às variações climáticas. Uma análise consolidada das tendências de todo o período (2017-2021) será apresentada em uma seção posterior, permitindo conclusões mais aprofundadas.

O mapa do Índice de Vegetação por Diferença Normalizada (NDVI) para 22 de junho de 2018 (Figura 12) revela alterações significativas na biomassa vegetal em comparação com 2017. Visualmente, observa-se uma aparente perda de vigor em áreas que antes apresentavam vegetação densa.


Figura 12 - Mapa do NDVI em Barreiros/PE para o ano de 2018.



Fonte: Elaborada pelo próprio autor (2025).

O histograma (Figura 13) corrobora essa observação, mostrando uma redução na amplitude do pico de valores mais altos e um leve deslocamento para a esquerda, indicando uma menor predominância de vegetação vigorosa. Este comportamento é consistente com os efeitos de um período de estresse hídrico, que pode resultar na perda de cobertura vegetal herbácea e na senescência de certas espécies.

Figura 13 - Histograma do NDVI – 2018.




Fonte: Elaborada pelo próprio autor (2025).

A consequência mais evidente das condições climáticas de 2018 é a clara retração dos corpos d'água, conforme destacado pelo mapa do Índice de Água por

Diferença Normalizada Modificado (MNDWI) (Figura 14). O leito do Rio Una aparece visivelmente mais estreito, e a extensão de áreas alagadas diminuiu drasticamente.


Figura 14 – Mapa do MNDWI em Barreiros/PE para o ano de 2018.



Fonte: Elaborada pelo próprio autor (2025).

O histograma do MNDWI (Figura 15) quantifica essa mudança, com um aumento na frequência de valores negativos (superfícies terrestres) e uma redução expressiva dos valores positivos, que representam a água. Essa retração hídrica valida a sensibilidade do MNDWI para monitorar a disponibilidade de água superficial (Xu, 2006) e está diretamente alinhada com as condições climáticas do ano.


Figura 15 - Histograma do MNDWI – 2018.



Fonte: Elaborada pelo próprio autor (2025).

Em contraste com as mudanças na vegetação e na água, o mapa do Índice de Diferença Normalizada de Áreas Construídas (NDBI) (Figura 16) apresenta uma aparente estabilidade, com poucas alterações visíveis em larga escala na mancha urbana.


Figura 16 - Mapa do NDBI em Barreiros/PE para o ano de 2018.



Fonte: Elaborada pelo próprio autor (2025).

O histograma (Figura 17) corrobora esta análise e revela uma característica importante: uma distribuição bimodal. A queda observada no centro do gráfico indica a presença de duas classes espectrais dominantes e bem definidas na paisagem. O primeiro pico, em valores negativos, corresponde à assinatura de superfícies não construídas (vegetação e água), enquanto o segundo pico, em valores positivos, representa a mancha urbana. O vale entre eles, próximo ao valor zero, demonstra uma boa separabilidade entre essas classes, o que é favorável para a classificação do uso do solo. Adicionalmente, o sutil aumento na frequência de valores positivos em comparação ao ano anterior pode indicar um leve adensamento ou expansão da malha urbana, consistente com as tendências de urbanização documentadas em outros estudos (Hashim et al., 2023; Lefulebe et al., 2023).


Figura 17 - Histograma do NDBI – 2018.



Fonte: Elaborada pelo próprio autor (2025).

O mapa do Índice de Solo Exposto (BSI) (Figura 18) indica um aumento nas áreas com solo nu em comparação com 2017.


Figura 18 - Mapa do BSI em Barreiros/PE para o ano de 2018.



Fonte: Elaborada pelo próprio autor (2025).

O histograma (Figura 19) confirma essa tendência, com um deslocamento da distribuição para valores mais positivos. Este aumento na exposição do solo é uma consequência direta e esperada da retração hídrica e da perda de cobertura vegetal de menor porte, um padrão documentado em áreas que passam por períodos de menor pluviosidade (Rasul et al., 2018).

Figura 19 -Histograma do BSI – 2018.



Fonte: Elaborada pelo próprio autor (2025).

5.1.4. Estatísticas descritivas e distribuição percentual dos Índices Espectrais - 2018

A análise quantitativa dos índices espectrais para a imagem de 22 de junho de 2018 permite avaliar as mudanças na paisagem em um cenário climático distinto do ano anterior, marcado pela finalização de um evento de seca na região (Lima et al., 2022). As estatísticas descritivas (Tabela 9) e a distribuição percentual dos pixels por classes de índice (Tabela 10) fornecem a base para esta discussão.

Tabela 9 - Estatísticas descritivas dos Índices Espectrais – 2018.

Índice	Mínimo	Máximo	Média	Mediana	Desvio Padrão	Assimetria	Curtose
NDVI	-0,1774	0,7128	0,3631	0,3925	0,1916	-0,4393	-0,6701
MNDWI	-1,0000	0,2422	-0,3159	-0,3236	0,1075	0,2412	11,2956
NDBI	-0,4777	1,0000	-0,0493	-0,0560	0,1726	1,0653	5,0679
BSI	-0,4721	1,0000	-0,0938	-0,0932	0,1763	1,0468	5,5152

Fonte: Elaborada pelo próprio autor (2025).

Tabela 10 - Distribuição percentual dos pixels por intervalo de valores dos Índices Espectrais - 2018

Índice	Intervalo	Percentual (%)
NDVI	< 0,0	3,33
NDVI	0 a < 0,2	20,85
NDVI	0,2 a < 0,4	26,84
NDVI	0,4 a < 0,6	40,70
NDVI	>= 0,6	8,27
MNDWI	< 0,00	97,35
MNDWI	0,0 a < 0,2	2,65
MNDWI	>= 0,2	0,00
NDBI	< 0,00	59,45
NDBI	0,0 a < 0,06	11,99
NDBI	>= 0,06	28,56
BSI	< 0,00	64,65
BSI	0,0 a < 0,08	18,73
BSI	>= 0,0	16,62

Fonte: Elaborada pelo próprio autor (2025).

A análise quantitativa dos índices para 2018 revela uma paisagem em transformação, influenciada tanto pelas condições climáticas quanto pela contínua pressão antrópica. O NDVI apresentou um comportamento complexo: apesar do cenário de menor disponibilidade hídrica — condição documentada como o final de um evento de seca na região (Lima et al., 2022), que contrasta com o pico de chuvas esperado para o mês de junho, conforme o climograma (Figura 2) — a categoria de vegetação mais densa (NDVI entre 0,4 e 0,6) tornou-se a mais predominante, com 40,70% da área. A literatura indica que a resposta do NDVI a eventos de precipitação é complexa e pode variar conforme o tipo de vegetação e o histórico de uso do solo,

o que pode explicar a resiliência de espécies de porte maior em detrimento da vegetação herbácea em períodos mais secos (Tan et al., 2015; Pei et al., 2021).

A resposta da paisagem às condições climáticas mais secas é visível na retração dos corpos d'água. O MNDWI apresentou o sinal mais claro dessa mudança, com uma notável redução da classe de "água aberta" ($\geq 0,2$) para 0,00%. Essa diminuição drástica da proporção de água é um forte indicador da retração hídrica, corroborando o cenário de um ano que marcou a finalização de um evento de seca na região (Lima et al., 2022) e a sensibilidade do índice em detectar variações na superfície hídrica (Xu, 2006; Hashim et al., 2023).

Enquanto isso, a dinâmica de urbanização continuou sua tendência de avanço. O NDBI mostrou que a classe de "áreas construídas" ($\geq 0,06$) aumentou de 26,30% em 2017 para 28,56% em 2018. Embora sutil, esse crescimento anual é consistente com o processo contínuo de expansão urbana observado em outros estudos de caso, onde a conversão de áreas naturais ou agrícolas para superfícies impermeáveis é uma constante (Hashim et al., 2023; Lefulebe et al., 2023). A classe de "áreas de transição" (11,99%) manteve-se estável, reforçando seu papel como zona de potencial expansão.

Por fim, o BSI refletiu a dinâmica entre a regeneração da vegetação e a pressão antrópica. A classe "solo exposto" (0,0 a $< 0,08$) apresentou uma leve redução, passando a ocupar 18,73% da área, possivelmente devido à densificação da vegetação em algumas áreas. Em contrapartida, a classe "transição/misto" ($\geq 0,08$) aumentou para 16,62%. Este aumento pode indicar tanto novas áreas em processo de construção quanto a maior evidência da confusão espectral entre solos nus e áreas construídas em um cenário com menor umidade, conforme apontado por Rasul et al. (2018).


5.1.5. Distribuição espacial dos Índices Espectrais – 2021

A análise da distribuição espacial dos índices espectrais para a imagem de 26 de junho de 2021 é fundamental para consolidar a análise multitemporal, permitindo observar a evolução da cobertura do solo no médio prazo. Esta etapa avalia tanto a recuperação de feições impactadas pelas condições climáticas de 2018 quanto a persistência de tendências de longo prazo, como a expansão urbana. A escolha do ano de 2021, influenciado pelo fenômeno La Niña e por chuvas irregulares (Colussi et al., 2023), fornece um cenário distinto para a avaliação da dinâmica da paisagem.

Uma análise quantitativa e consolidada das tendências de todo o período (2017-2021) será apresentada na seção subsequente.


O mapa do Índice de Vegetação por Diferença Normalizada (NDVI) (Figura 20) e seu histograma (Figura 21) indicam uma recuperação geral na densidade e vigor da vegetação em comparação com 2018. Quando comparado a 2017, embora o padrão espacial geral se mantenha, a análise quantitativa revela que o ano de 2021 apresentou uma cobertura de vegetação densa e muito densa superior (48,09%) à registrada no início do período (45,05%). Esta recuperação da biomassa vegetal sugere uma resposta positiva da paisagem a condições climáticas potencialmente mais favoráveis, um padrão de resiliência da vegetação que pode ser efetivamente monitorado pelo NDVI (Pei et al., 2021).

Figura 20 - Mapa do NDVI em Barreiros/PE para o ano de 2021.



Fonte: Elaborada pelo próprio autor (2025).


Figura 21 – Histograma do NDVI - 2021



Fonte: Elaborada pelo próprio autor (2025).


A recuperação também é observada nos corpos hídricos, conforme aponta o Índice de Água por Diferença Normalizada Modificado (MNDWI) (Figuras 22 e 23). O mapa mostra uma sutil, porém visível, expansão das áreas com valores positivos em comparação com o cenário de retração de 2018. Esta observação indica uma recuperação parcial da disponibilidade hídrica superficial, embora sem atingir os níveis observados no período mais úmido de 2017, o que reforça a eficácia do MNDWI para monitorar variações na extensão de corpos d'água em diferentes cenários climáticos (Xu, 2006; Du et al., 2016).

Figura 22 - Mapa do MNDWI em Barreiros/PE para o ano de 2021.



Fonte: Elaborada pelo próprio autor (2025).


Figura 23 - Histograma do MNDWI – 2021.



Fonte: Elaborada pelo próprio autor (2025).

Em contrapartida à recuperação parcial das feições naturais, a tendência de expansão urbana continuou e se intensificou. O mapa do Índice de Diferença Normalizada de Áreas Construídas (NDBI) (Figura 24) exibe um claro adensamento das áreas com valores positivos na porção central do município, além do surgimento de novas áreas nas periferias, caracterizando um processo de contínua conversão do uso do solo que encontra paralelo em estudos de caso similares (Hashim et al., 2023; Lefulebe et al., 2023).


Figura 24 - Mapa do NDBI em Barreiros/PE para o ano de 2021



Fonte: Elaborada pelo próprio autor (2025).

A comparação do histograma de 2021 (Figura 25) com os dos anos anteriores (Figuras 9 e 17) quantifica esta mudança, revelando um aumento progressivo e notável na frequência de valores positivos. Este crescimento contínuo da mancha urbana é a tendência mais marcante do período e está alinhado com processos de urbanização acelerada documentados em outros estudos de caso, que também utilizaram o NDBI para monitorar a conversão do uso do solo (Hashim et al., 2023; Lefulebe et al., 2023).

Figura 25 - Histograma do NDBI – 2021.



Fonte: Elaborada pelo próprio autor (2025).


Por fim, o Índice de Solo Exposto (BSI) (Figuras 26 e 27) para 2021 apresenta um cenário complexo. Embora a recuperação da vegetação sugira uma potencial diminuição do solo exposto, a expansão urbana pode ter criado novas áreas de solo nu em zonas de construção. O resultado é a persistência de um pico de valores positivos no histograma, indicando que a pressão antrópica se sobrepõe, em parte, à regeneração natural. Esta dinâmica, onde o BSI captura tanto solos naturais quanto áreas em processo de urbanização, é um desafio metodológico conhecido, dada a semelhança espectral entre essas feições (Rasul et al., 2018).

Figura 26 - Mapa do BSI em Barreiros/PE para o ano de 2021.



Fonte: Elaborada pelo próprio autor (2025).

Figura 27 - Histograma do BSI – 2021.



Fonte: Elaborada pelo próprio autor (2025).

5.1.6. Estatísticas descritivas e distribuição percentual dos Índices Espectrais – 2021

A análise quantitativa dos índices para a imagem de 26 de junho de 2021 conclui a série temporal, permitindo avaliar a evolução da paisagem no médio prazo em um cenário influenciado pelo fenômeno La Niña e por chuvas irregulares (Colussi et al., 2023). As estatísticas descritivas (Tabela 11) e a distribuição percentual (Tabela 12) fornecem os dados para a discussão que se segue.

Tabela 11 - Estatísticas descritivas dos Índices Espectrais – 2021

Índice	Mínimo	Máximo	Média	Mediana	Desvio Padrão	Assimetria	Curtose
NDVI	-1,0000	0,7220	0,3557	0,3843	0,2062	-0,6533	0,0257
MNDWI	-1,0000	0,2827	-0,3136	-0,3275	0,1290	1,2399	9,4281
NDBI	-0,4296	1,0000	-0,0462	-0,0574	0,1770	1,0864	4,6120
BSI	-0,4772	1,0000	-0,0925	-0,0922	0,1799	1,0300	5,1408

Fonte: Elaborada pelo próprio autor (2025).

Tabela 12 - Distribuição percentual dos pixels por intervalo de valores dos Índices Espectrais – 2021.

Índice	Intervalo	Percentual (%)
NDVI	< 0,0	3,87
NDVI	0 a < 0,2	21,44
NDVI	0,2 a < 0,4	26,59
NDVI	0,4 a < 0,6	39,13
NDVI	>= 0,6	8,96
MNDWI	< 0,00	96,17
MNDWI	0,0 a < 0,2	2,38
MNDWI	>= 0,2	1,45
NDBI	< 0,00	60,45
NDBI	0,0 a < 0,06	10,43
NDBI	>= 0,06	29,12
BSI	< 0,00	64,35
BSI	0,0 a < 0,08	17,55
BSI	>= 0,0	18,10

Fonte: Elaborada pelo próprio autor (2025).

A análise dos dados de 2021 revela a consolidação de tendências antrópicas e a resposta dinâmica da cobertura natural. A cobertura vegetal, analisada pelo NDVI, apresentou uma condição robusta, com as classes de vegetação densa e muito densa somando 48,09% da área, um patamar superior ao de 2017 (45,05%). Esta recuperação do vigor da vegetação após o cenário mais seco de 2018 sugere uma resiliência da paisagem a variações climáticas, um padrão que pode ser efetivamente monitorado pelo índice (Pei et al., 2021).

A recuperação também é visível na hidrografia. O MNDWI mostra um restabelecimento da classe de "água aberta" ($\geq 0,2$) para 1,45%, após ter sido zerada em 2018. Este aumento na proporção de água, embora não tenha atingido os níveis de 2017, indica uma recuperação da disponibilidade hídrica superficial e reforça a eficácia do MNDWI para monitorar variações na extensão de corpos d'água em diferentes cenários climáticos (Xu, 2006; Du et al., 2016).

A tendência mais expressiva no período, contudo, é a consolidação da expansão urbana. A proporção de "áreas construídas" (NDBI $\geq 0,06$) alcançou 29,12%, seu maior valor na série histórica. Este avanço contínuo é um forte indicativo de um processo de urbanização acelerado, alinhado com as tendências de conversão do uso do solo documentadas em outros estudos de caso em paisagens semelhantes (Hashim et al., 2023; Lefulebe et al., 2023).

Finalmente, a análise do BSI revela uma dinâmica-chave da transformação do solo. A classe "solo exposto" (0,0 a $< 0,08$) continuou sua tendência de redução, chegando a 17,55%. Em contrapartida, a classe "transição/misto" ($\geq 0,08$) continuou a crescer, atingindo 18,10%. Essa trajetória dupla — diminuição do solo exposto e aumento da área de transição/mista — sugere fortemente a contínua conversão do solo nu para novas frentes de urbanização, sendo a classe "Transição/misto" um provável indicador de áreas em construção, onde a confusão espectral com superfícies construídas é mais acentuada (Rasul et al., 2018).

5.1.7. Síntese e tendências temporais dos Índices Espectrais (2017-2021)

A análise das estatísticas descritivas revela tendências claras. O NDBI e o BSI para uma compreensão abrangente da dinâmica da cobertura do solo no período analisado, esta seção apresenta uma análise integrada das tendências temporais dos índices espectrais. A análise inicia-se com a avaliação das estatísticas descritivas ao longo dos três anos e, em seguida, aprofunda-se na evolução percentual das principais classes de cobertura do solo.

A Tabela 13 consolida as estatísticas descritivas para cada índice ao longo do período de 2017 a 2021, permitindo identificar as tendências gerais no comportamento dos dados.

Tabela 13 - Estatísticas descritivas por ano dos Índices Espectrais – (2017-2021)

Índice	Estatística	2017	2018	2021
NDVI	Mínimo	-0,2631	-0,1774	-1,0000
NDVI	Máximo	0,7381	0,7128	0,7220
NDVI	Média	0,3428	0,3631	0,3557
NDVI	Mediana	0,3643	0,3925	0,3843
NDVI	Desvio Padrão	0,2102	0,1916	0,2062
NDVI	Assimetria	-0,6105	-0,4393	-0,6533
NDVI	Curtose	-0,0425	-0,6701	0,0257
MNDWI	Mínimo	-1,0000	-1,0000	-1,0000
MNDWI	Máximo	0,2915	0,2422	0,2827
MNDWI	Média	-0,3036	-0,3159	-0,3136
MNDWI	Mediana	-0,3228	-0,3236	-0,3275
MNDWI	Desvio Padrão	0,1297	0,1075	0,1290
MNDWI	Assimetria	1,4509	0,2412	1,2399
MNDWI	Curtose	9,1975	11,2956	9,4281
NDBI	Mínimo	-0,4388	-0,4777	-0,4296
NDBI	Máximo	1,0000	1,0000	1,0000
NDBI	Média	-0,0499	-0,0493	-0,0462
NDBI	Mediana	-0,0595	-0,0560	-0,0574
NDBI	Desvio Padrão	0,1615	0,1726	0,1770
NDBI	Assimetria	1,1553	1,0653	1,0864
NDBI	Curtose	6,1013	5,0679	4,6120
BSI	Mínimo	-0,4901	-0,4721	-0,4772
BSI	Máximo	1,0000	1,0000	1,0000
BSI	Média	-0,0976	-0,0938	-0,0925
BSI	Mediana	-0,0948	-0,0932	-0,0922
BSI	Desvio Padrão	0,1691	0,1763	0,1799
BSI	Assimetria	0,9999	1,0468	1,0300
BSI	Curtose	5,9086	5,5152	5,1408

Fonte: Elaborada pelo próprio autor (2025).

A análise das estatísticas descritivas revela tendências claras. O NDBI e o BSI apresentaram um comportamento de leve, mas contínuo, aumento em seus valores médios ao longo dos anos, o que é um forte indicativo do adensamento ou expansão das áreas construídas e de solo exposto. O MNDWI, por sua vez, teve sua menor média em 2018, ano de menor precipitação e, conseqüentemente, menor suprimento hídrico, enquanto o NDVI demonstrou uma flutuação, refletindo a complexa resposta da vegetação a essa variação na disponibilidade de água.

Para complementar a análise, a Tabela 14 resume a evolução percentual das principais categorias de cada índice ao longo dos anos, destacando os dados mais relevantes para a discussão das tendências.

Tabela 14 - Distribuição percentual dos pixels por intervalo e ano de valores dos Índices Espectrais (2017-2021).

Índice	Intervalo	2017 (%)	2018 (%)	2021 (%)
NDVI	< 0,0	4,87	3,33	3,87
NDVI	0 a < 0,2	21,93	20,85	21,44
NDVI	0,2 a < 0,4	28,15	26,84	26,59
NDVI	0,4 a < 0,6	36,07	40,70	39,13
NDVI	>= 0,6	8,98	8,27	8,96
MNDWI	< 0,00	95,90	97,35	96,17
MNDWI	0,0 a < 0,2	2,35	2,65	2,38
MNDWI	>= 0,2	1,75	0,00	1,45
NDBI	< 0,00	61,98	59,45	60,45
NDBI	0,0 a < 0,06	11,72	11,99	10,43
NDBI	>= 0,06	26,30	28,56	29,12
BSI	< 0,00	66,49	64,65	64,35
BSI	0,0 a < 0,08	19,95	18,73	17,55
BSI	>= 0,08	13,56	16,62	18,10

Fonte: Elaborada pelo próprio autor (2025).

A tendência mais marcante e unidirecional do período é o crescimento da mancha urbana, conforme evidenciado pelo NDBI. A análise revela que a proporção de “áreas construídas” passou de 26,30% em 2017 para 29,12% em 2021. Este avanço progressivo, representando um aumento de quase três pontos percentuais, consolida a tendência de adensamento e expansão urbana no período. Tal dinâmica é um forte indicativo de urbanização acelerada, um fenômeno amplamente documentado em estudos de caso em países em desenvolvimento. A conversão de áreas naturais e agrícolas para superfícies impermeáveis é consistente com os achados de Lefulebe et al. (2023), que registraram um aumento de 13,6% em áreas construídas sob condições análogas, e de Hashim et al. (2023), que também monitoraram a expansão urbana sobre outras coberturas de solo.

A dinâmica hídrica, analisada pelo MNDWI, mostrou uma clara resposta às condições climáticas. O ano de 2017, associado a chuvas intensas (Alves et al., 2024), apresentou a maior área de "água aberta" (1,75%). Esta área foi drasticamente reduzida para 0,00% em 2018, um ano que marcou a finalização de um período de seca (Lima et al., 2022). Em 2021, um ano influenciado pelo fenômeno La Niña (Colussi et al., 2023), houve uma recuperação parcial para 1,45%, demonstrando a sensibilidade do índice em capturar a variabilidade interanual da disponibilidade de

água superficial, uma tendência também observada por Hashim et al. (2023) em outra bacia hidrográfica sob urbanização.

As consequências dessas pressões climáticas e antrópicas são visíveis no NDVI e no BSI. A cobertura de vegetação mais densa ($\text{NDVI} \geq 0,4$) demonstrou flutuações, indicando a resiliência da vegetação local e sua capacidade de responder a variações de precipitação, um padrão cuja monitorização é uma aplicação consolidada do NDVI (Pei et al., 2021). Em contrapartida, o BSI revelou uma dinâmica mais complexa: enquanto a classe “solo exposto” ($0,0 < 0,08$) apresentou uma leve, porém contínua, tendência de redução ao longo do período, a classe “transição/misto” ($\geq 0,08$) registrou um aumento progressivo, atingindo seu maior valor em 2021. Esta dinâmica ilustra um desafio metodológico, pois o BSI pode capturar tanto solos naturais quanto áreas em processo de urbanização, dada a semelhança espectral entre essas feições (Rasul et al., 2018).

Em suma, a análise multitemporal dos índices espectrais confirma que a paisagem de Barreiros é moldada por uma interação complexa, onde a resiliência dos sistemas naturais a variações climáticas ocorre em paralelo a uma contínua e crescente pressão da urbanização, que se consolida como o principal vetor de transformação permanente do uso e cobertura do solo.

5.2. CARACTERIZAÇÃO ESPAÇO-TEMPORAL DO USO E OCUPAÇÃO DO SOLO COM KNN


Esta subseção apresenta os resultados da classificação supervisionada das imagens, utilizando o classificador kNN. Os mapas temáticos e as análises quantitativas permitem uma compreensão detalhada das transformações na cobertura e uso do solo na área de estudo, fornecendo uma categorização temática que complementa a análise dos índices espectrais.

5.2.1. Mapas Temáticos de Uso e Ocupação do Solo – 2017

O mapa de uso e ocupação do solo para 27 de junho de 2017 (Figura 28) estabelece a linha de base da paisagem de Barreiros em um período associado a chuvas intensas (Alves et al., 2024). A análise visual do mapa revela a distribuição espacial das quatro classes temáticas — água, solo exposto, área urbana e vegetação

— cujas assinaturas espectrais foram definidas a partir de amostras de treinamento. No mapa, observa-se a Vegetação dominando a paisagem, o que é esperado para uma área inserida no bioma da Mata Atlântica.

Figura 28 - Mapa de Uso e Ocupação do Solo - Classificação kNN (2017).



Fonte: Elaborada pelo próprio autor (2025).

A classe área urbana apresenta o padrão espacial mais definido, concentrando-se notavelmente ao longo do curso do Rio Una, na porção central do município. Esta configuração delineia o principal eixo de ocupação e indica uma forte pressão antrópica sobre as áreas ribeirinhas, um padrão de desenvolvimento que frequentemente molda a paisagem em cidades com características similares. Em paralelo, a classe solo exposto aparece dispersa, frequentemente em áreas de transição entre a vegetação e o ambiente urbano ou em zonas de atividades agrícolas. Estas áreas de solo nu são importantes indicadores de transformação, pois representam zonas com potencial para futura conversão para o uso urbano (Lefulebe et al., 2023). Por fim, a classe Água corresponde ao leito do Rio Una e seus corpos adjacentes. O rio atravessa a área de estudo em um eixo leste-oeste, servindo como o principal elemento geográfico que estrutura a paisagem e condiciona a distribuição das demais classes de uso do solo.

5.2.2. Análise quantitativa das classes do LULC – 2017


A análise quantitativa da classificação kNN para 27 de junho de 2017 fornece os dados percentuais de cada classe de uso e cobertura do solo, estabelecendo a linha de base para a análise temporal. A Tabela 15 resume esta distribuição, que é visualmente representada no Gráfico 1.

Tabela 15 - Distribuição quantitativa das classes do LULC - Classificação kNN (2017)

Classe	Porcentagem (%)
Água	4,97
Solo exposto	25,18
Área urbana	25,65
Vegetação	44,21

Fonte: Elaborada pelo próprio autor (2025).

Gráfico 1 - Distribuição percentual das classes – Classificação kNN (2017)



Fonte: Elaborada pelo próprio autor (2025).

A análise dos dados quantitativos revela uma paisagem heterogênea, marcada por um equilíbrio entre a matriz natural e as áreas sob forte pressão antrópica. A classe Vegetação era a mais expressiva, abrangendo 44,21% do território, o que corrobora as observações do NDVI para o mesmo período e é consistente com a localização do município no bioma da Mata Atlântica.


O dado mais relevante para a análise da dinâmica de LULC é a substancial proporção de Área urbana, que já correspondia a 25,65% do território em 2017. Este percentual, concentrado ao longo do Rio Una, representa uma linha de base significativa de ocupação humana e serve como o principal indicador da pressão antrópica que impulsionará as transformações futuras. Adicionalmente, a significativa porção de solo exposto (25,18%), provavelmente associada a áreas agrícolas em pousio ou zonas de transição, é um componente crítico. A literatura aponta que grandes áreas de solo exposto em paisagens em desenvolvimento são frequentemente as primeiras a serem convertidas para uso urbano em processos de expansão, tornando-se um indicador chave para o monitoramento do crescimento da cidade (Lefulebe et al., 2023).

Por fim, a classe Água, com 4,97%, representa o Rio Una e corpos d'água adjacentes, servindo como o elemento geográfico estruturante em torno do qual as outras classes de uso do solo se distribuem. A configuração geral da paisagem em 2017, com este balanço entre áreas naturais, agrícolas/em transição e uma mancha urbana já consolidada, é consistente com a de outras paisagens em desenvolvimento que passam por processos de transformação (Hashim et al., 2024).

5.2.3. Mapas Temáticos de Uso e Ocupação do Solo – 2018

O mapa de uso e ocupação do solo de Barreiros/PE para o ano de 2018 (Figura 29) exhibe algumas alterações notáveis em comparação com 2017, refletindo o impacto de fatores como a menor quantidade de precipitação no ano de 2018.

Figura 29 - Mapa de Uso e Ocupação do Solo - Classificação kNN (2018).



Fonte: Elaborada pelo próprio autor (2025).

As alterações mais notáveis ocorreram nas classes que respondem dinamicamente às variações climáticas. A classe água apresenta uma redução perceptível em sua extensão, especialmente no leito principal do Rio Una, onde a lâmina d'água se apresenta mais estreita. Essa retração é consistente com a observação dos valores do MNDWI para o mesmo período. Em consequência direta, observa-se um aumento aparente na distribuição da classe solo exposto, que avança sobre áreas anteriormente cobertas por água ou por vegetação de menor porte, um indicativo claro do efeito das condições mais secas sobre a paisagem. A classe vegetação, embora ainda dominante, também exhibe sinais de estresse hídrico, com uma aparente diminuição na densidade geral.

Em contraste com essas mudanças dinâmicas na cobertura natural, a classe área urbana mantém seu padrão espacial concentrado ao longo do Rio Una, com poucas alterações visíveis em sua expansão em um intervalo de apenas um ano. Este comportamento diferenciado é esperado, pois enquanto a cobertura hídrica e vegetal

responde rapidamente a variações climáticas de curto prazo, a expansão urbana é um processo de transformação mais gradual e cumulativo, cujas tendências são mais bem observadas em séries temporais mais longas (Hashim et al., 2023; Lefulebe et al., 2023).

5.2.4. Análise quantitativa das classes do LULC – 2018

Para quantificar as mudanças na cobertura do solo entre 2017 e 2018, a Tabela 16 apresenta o percentual de área correspondente a cada classe, classificada pelo kNN para a data de 22 de junho de 2018.


Tabela 16 - Distribuição quantitativa das classes do LULC - Classificação kNN (2018)

Classe	Porcentagem (%)
Água	4,51
Solo exposto	19,40
Área urbana	29,81
Vegetação	46,28

Fonte: Elaborada pelo próprio autor (2025).

A proporção visual de cada classe na paisagem é ilustrada no Gráfico 2.

Gráfico 2 - Distribuição percentual das classes – Classificação kNN (2018)



Fonte: Elaborada pelo próprio autor (2025).

A análise quantitativa da classificação de 2018 revela uma paisagem em plena transformação, com a expansão urbana consolidando-se como o principal vetor de mudança. A classe área urbana registrou um aumento substancial, passando de 25,65% em 2017 para 29,81% em 2018. Este crescimento, possivelmente impulsionado por fatores como a migração rural-urbana, é consistente com as tendências de urbanização acelerada documentadas em outras paisagens em desenvolvimento, onde a alta taxa de natalidade e a busca por oportunidades econômicas impulsionam a expansão das cidades (Lefulebe et al., 2023).

A principal fonte de área para esta expansão parece ter sido a classe solo exposto, que apresentou uma notável redução de 25,18% em 2017 para 19,40% em 2018. Esta dinâmica sugere a conversão de áreas em transição (agrícolas em pousio ou degradadas) para superfícies construídas, um processo comum de adensamento e expansão urbana. Estudos como o de Hashim et al. (2024) também identificaram a diminuição de terras agrícolas e outros espaços abertos como uma consequência direta do aumento da área construída, validando a tendência observada.


A classe vegetação, por sua vez, apresentou um leve aumento percentual, passando de 44,21% para 46,28%. Este aumento, mesmo em um ano de menor precipitação, pode indicar que parte das áreas antes classificadas como solo exposto também passaram por um processo de regeneração ou densificação da vegetação esparsa. A análise dessas transições entre classes é fundamental para compreender a complexa dinâmica do LULC em curtos períodos de tempo (Lefulebe et al., 2023).

Por fim, a classe água apresentou uma redução percentual, passando de 4,97% para 4,51%. Esta diminuição, coerente com o cenário climático de menor disponibilidade hídrica, é uma tendência observada em outras bacias hidrográficas sob intensa pressão antrópica. De fato, os resultados convergem com os de Talukdar et al. (2020), que, ao analisarem a bacia do rio Barak, na Índia, também encontraram uma redução significativa na classe de corpos d'água (de 3,75% para 2,45%) ao longo de 20 anos, atribuindo-a à expansão urbana e agrícola. Essa convergência de resultados, ainda que em magnitudes distintas, reforça a hipótese de que o processo de urbanização impacta diretamente a superfície hídrica (Hashim et al., 2023; Lefulebe et al., 2023).

5.2.5. Mapas Temáticos de Uso e Ocupação do Solo – 2021

O mapa de uso e ocupação do solo para 26 de junho de 2021 (Figura 30), derivado da classificação kNN, permite uma avaliação da trajetória evolutiva da paisagem no médio prazo. A análise visual desta data revela a consolidação da tendência de expansão urbana em paralelo a uma recuperação parcial da cobertura natural.

Figura 30 - Mapa de Uso e Ocupação do Solo - Classificação kNN (2021).



Fonte: Elaborada pelo próprio autor (2025).

A classe água no Rio Una e seus afluentes apresenta uma extensão que, visualmente, parece ainda levemente menor ou comparável à observada em 2018, e significativamente menor que em 2017. Isso sugere uma persistência ou acentuação da retração hídrica na paisagem, impactando a visibilidade dos corpos d'água. Essa condição pode estar associada às observações do MNDWI para 2021, que também refletem as características da disponibilidade hídrica para o ano.

A classe vegetação mantém-se como um componente dominante na paisagem. Observa-se uma presença robusta de áreas vegetadas em 2021, com uma distribuição que pode indicar tanto a recuperação de áreas impactadas em 2018 quanto a manutenção de grandes extensões de cobertura vegetal densa. Essa estabilidade ou leve recuperação da vegetação é consistente com as tendências observadas no NDVI para 2021, que mostrou um bom vigor vegetal geral.

A classe de solo exposto continua a ser uma classe presente no município. A análise visual do mapa sugere uma persistência ou mesmo um aumento na distribuição dessas áreas em comparação com os anos anteriores. Esta observação encontra respaldo nas tendências do BSI para 2021, que indicam uma proporção relevante de solo nu na paisagem.

A classe área urbana demonstra uma tendência persistente de expansão e adensamento, que se intensificou ao longo do período analisado (2017 e 2018). É possível identificar visualmente a formação de novas áreas de urbanização, expandindo-se nas periferias do aglomerado urbano existente e avançando sobre zonas de transição. Essa progressão é consistente com os resultados do NDBI para 2021, que apontaram um aumento na proporção de áreas construídas.

5.2.6. Análise quantitativa das classes do LULC – 2021

Para quantificar a distribuição das classes de LULC no final do período analisado, a Tabela 17 apresenta o percentual de área correspondente a cada categoria, classificada pelo kNN para a data de 26 de junho de 2021 e o Gráfico 3 mostra visualmente a proporção de cada classe.

Tabela 17 - Distribuição quantitativa das classes do LULC - Classificação kNN (2021)

Classe	Porcentagem (%)
Água	3,93
Solo exposto	17,54
Área urbana	35,62
Vegetação	42,91

Fonte: Elaborada pelo próprio autor (2025).

Gráfico 3 - Distribuição percentual das classes – Classificação kNN (2021)



Fonte: Elaborada pelo próprio autor (2025).

A análise quantitativa de 2021 revela a consolidação da expansão urbana como a principal força de transformação da paisagem de Barreiros. A classe área urbana registrou um crescimento acentuado e contínuo, alcançando 35,62% do território. Este aumento progressivo, que representa um avanço de quase 10 pontos percentuais desde 2017, destaca uma forte pressão de urbanização, consistente com as análises do NDBI e alinhada às tendências de conversão do uso do solo documentadas em outros estudos de caso (Hashim et al., 2024; Lefulebe et al., 2023).

Esta expansão urbana parece ter ocorrido principalmente sobre as áreas de solo exposto, que continuaram sua trajetória de redução, atingindo 17,54% em 2021. A diminuição consistente desta classe ao longo dos anos sugere sua contínua conversão para superfícies construídas. Em paralelo, a classe água também continuou sua tendência de redução gradual, chegando a 3,93%. Esta diminuição progressiva dos corpos d'água, mesmo em um ano com recuperação hídrica em relação a 2018, é uma tendência preocupante frequentemente associada à pressão antrópica em bacias hidrográficas (Hashim et al., 2023).

A classe vegetação mostrou uma dinâmica complexa, com uma leve redução para 42,91% em 2021, após ter aumentado em 2018. Embora tenha havido uma

resiliência e recuperação do vigor vegetal (conforme o NDVI), este recuo percentual na área total classificada como vegetação sugere que a contínua expansão urbana já começa a impactar a matriz natural do município, convertendo áreas que antes eram vegetadas.

Em suma, a análise multitemporal da classificação kNN revela uma paisagem em constante transformação, onde a dinâmica de expansão da área urbana sobrepõe-se às flutuações da cobertura natural, consolidando-se como o principal vetor de mudança no uso e cobertura do solo em Barreiros.

5.2.7. Síntese e tendências temporais do LULC (2017-2021)


A análise consolidada da classificação kNN para o período de 2017 a 2021 permite quantificar as principais tendências de transformação da cobertura e uso do solo em Barreiros. A Tabela 18 e o Gráfico 4 resumem a evolução percentual das classes, fornecendo a base para a discussão que se segue.

Tabela 18 – Comparativo da distribuição das classes do LULC - Classificação kNN (2017-2021)

Classe	2017 (%)	2018 (%)	2021 (%)
Água	4,97	4,51	3,93
Solo exposto	25,18	19,40	17,54
Área urbana	25,65	29,81	35,62
Vegetação	44,21	46,28	42,91

Fonte: Elaborada pelo próprio autor (2025).

Gráfico 4 - Distribuição percentual das classes por ano – Classificação kNN (2017-2021).



Fonte: Elaborada pelo próprio autor (2025).

A análise temporal revela que a expansão da área urbana foi a força de transformação mais acentuada e contínua na paisagem de Barreiros. A classe "área urbana" aumentou em mais de 10 pontos percentuais em apenas quatro anos, passando de 25,65% em 2017 para 35,62% em 2021. Este avanço da urbanização é um fator crítico, e a magnitude desse crescimento é comparável à observada em outros estudos de caso em paisagens em desenvolvimento. Por exemplo, em um período similar, Lefulebe et al. (2023) constataram um aumento de 13,6% em áreas construídas na África do Sul, atribuindo-o a fatores como a migração rural-urbana e a alta taxa de natalidade, o que sugere que o processo observado em Barreiros se insere em uma tendência mais ampla.

A diminuição consistente da classe "solo exposto", que teve uma queda de mais de 7 pontos percentuais no período, sugere que estas áreas foram o principal alvo de conversão para o avanço da classe urbana, indicando um processo de adensamento e expansão sobre áreas já antropizadas ou em transição. Em paralelo, a classe "água" apresentou uma tendência decrescente contínua, passando de 4,97% para 3,93%. Esta redução, embora influenciada por variações climáticas, também pode refletir os impactos da urbanização nas margens dos rios. A diminuição de corpos d'água em paralelo ao crescimento de áreas construídas é uma tendência consistente com outros estudos que analisaram a dinâmica de LULC em bacias hidrográficas sob pressão urbana (Hashim et al., 2023; Lefulebe et al., 2023).

A classe "vegetação", embora tenha se mantido como a cobertura predominante, exibiu uma dinâmica mais complexa. O aumento inicial de 2017 para 2018, seguido por uma redução em 2021, indica não apenas a suscetibilidade a fatores ambientais, mas também a pressão da expansão urbana, que gradualmente converte áreas vegetadas em superfícies construídas, um padrão também observado por Lefulebe et al. (2023).

Contudo, a análise da classificação kNN para o período de 2017 a 2021 quantifica um processo de urbanização acelerada em Barreiros. Esta expansão, ao ocorrer sobre áreas de solo exposto e vegetação, e em paralelo a uma redução da superfície hídrica, é o principal vetor de alteração da paisagem e, conseqüentemente, da intensificação dos riscos ambientais no município, como a conseqüente impermeabilização do solo que tende a aumentar o escoamento superficial (Lefulebe et al., 2023).

5.2.8. Avaliação da precisão da classificação do kNN

Para validar os mapas temáticos apresentados e quantificar a performance do classificador, a precisão do modelo kNN foi avaliada para cada ano do período de estudo. Os resultados desta análise, incluindo as métricas de desempenho e a discussão dos achados, são detalhados a seguir.


5.2.8.1. Otimização do parâmetro k

A escolha do número ideal de vizinhos (k) é um passo crítico na calibração do classificador kNN, pois influencia diretamente a complexidade do limite de decisão e a capacidade de generalização do modelo (Kusuma et al., 2023). Para determinar o valor mais adequado de k para cada ano, foi realizada uma avaliação sistemática do desempenho do modelo em um intervalo de k de 1 a 10, utilizando-se uma proporção de 30% dos dados para teste. A performance foi avaliada com base nas métricas de Acurácia Global e Coeficiente Kappa, e os resultados estão ilustrados nos Gráficos 5, 6 e 7.

A análise desses gráficos revelou que o valor de k que otimiza o desempenho do modelo variou ao longo dos anos, indicando uma adaptação necessária do modelo às características específicas da paisagem em cada período. Para 2017 (Gráfico 5), o valor de k=9 foi selecionado. Em 2018 (Gráfico 6), o valor ótimo foi k=5. Já em 2021 (Gráfico 7), o valor de k=3 foi o escolhido.


Essa variação na seleção do k demonstra a importância da calibração de hiperparâmetros em análises multitemporais. A busca pelo k ótimo visa encontrar um equilíbrio entre a precisão nos dados conhecidos e a capacidade de classificar corretamente dados não vistos, evitando os problemas de overfitting (sobreajuste), que é comum para valores muito baixos de k (como k=1), e de oversmoothing (excesso de suavização), que pode ocorrer com valores de k muito altos (Zhang et al., 2019). A flutuação do k ótimo entre os anos sugere que a complexidade e a separabilidade espectral entre as classes de LULC mudaram, exigindo diferentes níveis de flexibilidade do modelo para alcançar a performance máxima em cada cenário (Lefulebe et al., 2023).

Gráfico 5 - Desempenho do kNN por número de vizinhos (k) – Ano: 2017.




Fonte: Elaborada pelo próprio autor (2025).

Gráfico 6- Desempenho do kNN por número de vizinhos (k) – Ano: 2018.



Fonte: Elaborada pelo próprio autor (2025).

Gráfico 7 - Desempenho do kNN por número de vizinhos (k) – Ano: 2021.



Fonte: Elaborada pelo próprio autor (2025).

5.2.8.2. Avaliação da precisão da classificação do kNN


A avaliação quantitativa da precisão do classificador kNN para os anos de 2017, 2018 e 2021 foi realizada utilizando as métricas definidas na metodologia, aplicadas sobre o conjunto de amostras de teste (30% do total). A divisão do conjunto de amostras em 70% para treinamento e 30% para validação do modelo segue uma prática consolidada na literatura de aprendizado de máquina. Essa proporção busca garantir um volume robusto de dados para o treinamento, ao mesmo tempo que reserva um subconjunto significativo e independente para a avaliação imparcial da performance do classificador (Géron, 2023). Os resultados consolidados são apresentados na Tabela 19, e as matrizes de confusão para cada ano nas Figuras 31, 32 e 33.

Tabela 19 – Relatório das métricas de desempenho consolidado – 2017, 2018 e 2021

Classe/Métrica	Precision (2017)	Recall (2017)	F1-Score (2017)	Precision (2017)	Recall (2017)	F1-Score (2017)	Precision (2017)	Recall (2017)	F1-Score (2017)
Água	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00
Solo exposto	0,92	1,00	0,96	1,00	1,00	1,00	1,00	1,00	1,00
Área urbana	1,00	0,92	0,96	1,00	1,00	1,00	1,00	1,00	1,00
Vegetação	0,92	0,86	0,859	1,00	1,00	1,00	1,00	1,00	1,00
Acurácia Global	0,95			1,00			1,00		
Kappa	0,93			1,00			1,00		


Fonte: Elaborada pelo próprio autor (2025).

Figura 31 - Matriz de Confusão - kNN (2017)




Fonte: Elaborada pelo próprio autor (2025).

Figura 32 - Matriz de Confusão - kNN (2018)



Fonte: Elaborada pelo próprio autor (2025).

Figura 33 - Matriz de Confusão - kNN (2021)



Fonte: Elaborada pelo próprio autor (2025).

A análise da Tabela 19 demonstra a alta eficácia do classificador kNN na discriminação das classes de LULC na área de estudo. Para o ano de 2017, o modelo alcançou uma Acurácia Global de 95% e um Coeficiente Kappa de 0,93. De acordo com a escala de referência, um Kappa superior a 0,81 representa uma concordância "quase perfeita" (Landis e Koch, 1977). Estes valores são comparáveis, e em alguns casos superiores, aos resultados obtidos em pesquisas similares. Por exemplo, Lefulebe et al. (2023), ao utilizar o kNN em uma paisagem complexa, reportaram acurácias globais de 98,31% e 96,54% em anos distintos, enquanto Kusuma et al. (2023) obteve 90,75% de acurácia, o que posiciona o desempenho deste estudo em um patamar de alta confiabilidade. Embora o kNN tenha se mostrado altamente eficaz, outros classificadores consolidados na literatura, como o Random Forest (RF) e o Support Vector Machine (SVM), poderiam apresentar performances distintas, como demonstrado em estudos comparativos que utilizam dados similares (Abdi, 2019). Uma análise aprofundada entre estes algoritmos representaria um caminho interessante para trabalhos futuros, ainda que os resultados obtidos com kNN já atendam aos objetivos propostos com excelente acurácia.

Uma análise pormenorizada do desempenho por classe para 2017, por meio das métricas de Precision e Recall, revela que a maioria das classes foi identificada com altíssima precisão. A principal fonte de erro, embora mínima, concentrou-se na classe "vegetação", que apresentou um Recall de 0,86. A análise da matriz de

confusão (Figura 31) indica que essa leve imprecisão se deu por uma confusão pontual com a classe "área urbana". Este é um desafio comum em paisagens urbanas heterogêneas, onde a vegetação em quintais e parques pode apresentar respostas espectrais complexas, dificultando a separação de outras classes de uso do solo (Hashim et al., 2023).

Para os anos de 2018 e 2021, o modelo demonstrou um desempenho excepcionalmente alto, alcançando Acurácia Global e Coeficiente Kappa de 1,00. O desempenho em 2017, embora ainda excelente, pode estar associado à maior complexidade espectral da paisagem naquele ano, que foi impactada por um período de chuvas intensas (Alves et al., 2024). Sugere-se que a saturação de água no solo e na vegetação pode ter gerado "pixels mistos", aumentando a dificuldade de separação entre as classes, um desafio recorrente em paisagens heterogêneas (Hashim et al., 2023). Embora notáveis, estes resultados de classificação perfeita nas amostras de teste devem ser interpretados no contexto da metodologia. O uso de um conjunto de amostras balanceado, como o empregado nesta pesquisa, é um pré-requisito que comprovadamente melhora a performance de classificadores de aprendizado de máquina (Kusuma et al., 2023).

Além disso, a distinção espectral clara entre as quatro macroclasses (água, solo exposto, área urbana e vegetação) provavelmente facilitou a alta performance. A ausência de subcategorias mais granulares contribui para uma maior separabilidade entre as classes, um fator que pode ser decisivo no desempenho final, como observado por Abdi (2019), cujo estudo com 8 classes de LULC resultou em acurácias ligeiramente menores. É importante notar que, embora o kNN tenha se mostrado perfeito para este conjunto de dados, a literatura aponta que o método pode enfrentar desafios em datasets mais complexos ou desbalanceados (Zhang et al., 2019).

5.3. ANÁLISE DO MAPA DE SUSCETIBILIDADE VIA AHP

A aplicação do AHP permitiu ponderar a importância relativa de cada fator condicionante e, subsequentemente, gerar o mapa de suscetibilidade ambiental para o município de Barreiros.

5.3.1. Ponderação dos Fatores Condicionantes

O primeiro resultado da aplicação do AHP consiste na determinação dos pesos de importância para cada fator, derivados da matriz de comparação par a par. É importante ressaltar que estes pesos não são extraídos de uma única referência, mas sim o resultado dos julgamentos feitos na matriz de comparação, desenvolvida especificamente para este estudo. Tais julgamentos foram fundamentados na literatura de referência, que consistentemente aponta a maior influência de fatores como o uso do solo, a hipsometria e a densidade urbana em estudos de suscetibilidade a inundações (Weiss e Pippi, 2019; Selvam e Antony Jebamalai, 2023; Bokhari et al., 2024). A análise foi validada com uma Razão de Consistência (RC) de 0,032, que, por ser inferior ao limiar de 0,1, atesta a consistência dos julgamentos (Saaty, 1990; Khaddari et al., 2023). Os pesos finais, que representam a influência relativa de cada variável na suscetibilidade ambiental de Barreiros, estão apresentados na Tabela 20.

Tabela 20 – Pesos finais dos Fatores Condicionantes.

Fator Condicionante	Peso (%)
Uso e cobertura do solo	32,67
Hipsometria	26,73
Densidade urbana	22,28
Pedologia	9,16
NDVI	9,16

Fonte: Elaborada pelo próprio autor (2025).

A análise dos pesos (Tabela 20) revela que o Uso e Cobertura do Solo foi considerado o fator mais influente na suscetibilidade, com um peso de 32,67%. Este resultado ressaltar a importância da forma como a paisagem é modificada pela ação humana, onde superfícies impermeáveis contribuem mais para o risco do que superfícies naturais, uma premissa fundamental em estudos de suscetibilidade ambiental (Weiss e Pippi, 2019).

Em seguida, a Hipsometria (26,73%) e a Densidade Urbana (22,28%) foram os fatores mais relevantes. A alta importância atribuída à Hipsometria é consistente com diversos modelos de suscetibilidade a inundações, que apontam a elevação como um controle primário na acumulação de fluxos de água (Khaddari et al., 2023; Bokhari et al., 2024). Embora a topografia seja um controle físico fundamental, no contexto de


Barreiros, a dinâmica de transformação antrópica se mostrou um vetor de risco mais acentuado, justificando o maior peso atribuído ao uso do solo. Juntos, esses três primeiros fatores — Uso do Solo, Hipsometria e Densidade Urbana — somam mais de 81% do peso do modelo, indicando que a suscetibilidade em Barreiros é predominantemente controlada pela interação entre a topografia do terreno e a intensidade da ocupação humana.

Os fatores Pedologia e NDVI, com pesos idênticos de 9,16%, foram considerados de menor importância relativa, atuando como variáveis secundárias no modelo. Embora menos influentes nesta configuração específica, a pedologia e a cobertura vegetal (representada pelo NDVI) são consistentemente incluídas em análises multicritério por seu papel na modulação dos processos de infiltração e escoamento superficial (Selvam e Antony Jebamalai, 2023; Dotto et al., 2023). A seguir, são apresentados os mapas dos fatores condicionantes utilizados na modelagem de suscetibilidade:

I. Hipsometria

O mapa de Hipsometria (Figura 34) ilustra a distribuição das altitudes na área de estudo. Este fator é crucial na análise de suscetibilidade, pois a força da gravidade direciona o fluxo de água de áreas mais elevadas para as mais baixas, onde a acumulação tende a ocorrer. As regiões de menor altitude são as mais propensas a reter água e, conseqüentemente, a sofrer inundações.

Figura 34 - Mapa de Hipsometria - AHP.




Fonte: Elaborada pelo próprio autor (2025).

II. Uso e cobertura do solo

O mapa de Uso e Cobertura do Solo (Figura 35) reflete a forma como a paisagem está ocupada. A relevância deste fator reside no fato de que o padrão de uso e ocupação do solo influencia diretamente processos hidrológicos como escoamento superficial e taxa de infiltração. Áreas com vegetação densa tendem a apresentar menor potencial de inundação devido à sua capacidade de retenção de água e aumento da infiltração, enquanto áreas urbanas, majoritariamente impermeáveis, e solos expostos, favorecem o escoamento rápido e o aumento do risco.

Figura 35 - Mapa de uso e cobertura do solo - AHP.




Fonte: Elaborada pelo próprio autor (2025).

III. Índice de Diferença Normalizada da Vegetação (NDVI)

O mapa do NDVI (Figura 36) representa a biomassa e o vigor da vegetação. É um indicador relevante para a dinâmica hídrica, pois a vegetação, por meio de processos como interceptação e evapotranspiração, afeta a quantidade de água que atinge e permanece no solo. Áreas com alto NDVI indicam maior cobertura vegetal e, consequentemente, maior capacidade de mitigar o escoamento superficial e promover a infiltração.

Figura 36 - Mapa de NDVI - AHP.




Fonte: Elaborada pelo próprio autor (2025).

IV. Densidade Urbana

O mapa de Densidade Urbana (Figura 37) ilustra a concentração de áreas construídas e urbanizadas. Regiões com maior densidade urbana apresentam maior impermeabilização do solo, o que reduz significativamente a infiltração de água e aumenta o volume e a velocidade do escoamento superficial, elevando a suscetibilidade a inundações e alagamentos.

Figura 37 - Mapa de Densidade Urbana - AHP.




Fonte: Elaborada pelo próprio autor (2025).

V. Pedologia

O mapa de Pedologia (Figura 38) detalha os tipos de solo presentes na área de estudo. A constituição do solo é um fator determinante para as características de infiltração e escoamento da água. Solos argilosos ou compactados, por exemplo, tendem a ter baixa permeabilidade e, portanto, contribuem para um maior escoamento superficial, enquanto solos arenosos favorecem a infiltração, reduzindo o risco de acúmulo de água na superfície.

Figura 38 - Mapa de Pedologia - AHP.



Fonte: Elaborada pelo próprio autor (2025).


5.3.2. Mapa de Suscetibilidade a Inundações

A combinação ponderada dos fatores resultou no mapa final de suscetibilidade (Figura 39), que foi reclassificado em cinco classes: Muito Baixa, Baixa, Média, Alta e Muito Alta.

O mapa de suscetibilidade a inundações de Barreiros/PE (Figura 39) visualiza as áreas do município conforme seu potencial de serem afetadas por eventos de alagamento ou inundação. As diferentes colorações representam classes de suscetibilidade, variando geralmente de muito baixa a muito alta. Observa-se que as regiões de maior suscetibilidade (tons mais vermelhos) tendem a se concentrar em áreas de baixa altitude, ao longo dos cursos d'água e em zonas urbanizadas, onde a impermeabilização do solo e a proximidade com rios ampliam o risco. Esta distribuição espacial é coerente e esperada, validando a lógica do modelo AHP, pois as áreas de maior destaque são precisamente aquelas onde os fatores de maior peso — Uso do Solo, Hipsometria e Densidade Urbana — se sobrepõem, não havendo, sob a ótica da metodologia aplicada, outra área que devesse apresentar maior destaque.

Em contraste, áreas de menor suscetibilidade (tons mais azuis) são geralmente encontradas em altitudes mais elevadas e com maior cobertura vegetal. Essa concentração de áreas de maior risco em baixas altitudes, próximo a cursos d'água e em zonas urbanizadas, é um achado comum em estudos de suscetibilidade a inundações. Selvam e Antony Jebamalai (2023) também classificaram as regiões vulneráveis a inundações em categorias de muito baixa a muito alta, identificando as áreas mais próximas aos rios e as áreas urbanizadas como as mais suscetíveis. Khaddari et al. (2023) igualmente encontraram correlações próximas entre áreas propensas a inundações e a proximidade de rios, fluxo de acumulação e elevação, com as áreas de maior risco concentradas a jusante e em áreas urbanizadas. Bokhari et al. (2024) também observaram que áreas de menor elevação e menor declividade (baixas altitudes) exibem a maior suscetibilidade a inundações.

Figura 39 - Mapa de Suscetibilidade a Inundações em Barreiros/PE.



Fonte: Elaborada pelo próprio autor (2025).

6. CONSIDERAÇÕES FINAIS

Este estudo analisou a dinâmica espaço-temporal do uso e cobertura do solo no município de Barreiros/PE entre 2017 e 2021 e modelou a suscetibilidade ambiental do território. Para tal, empregou-se uma abordagem integrada com Sensoriamento Remoto, o classificador de aprendizado de máquina kNN e o Processo de Hierarquia Analítica (AHP). A pesquisa alcançou seus objetivos, gerando um diagnóstico detalhado das transformações da paisagem e identificando suas áreas mais críticas.

Os resultados revelaram duas forças principais que moldam a paisagem local: a resposta dinâmica da cobertura natural às variações climáticas e uma tendência contínua e progressiva de expansão urbana. A cobertura hídrica (MNDWI) e vegetal (NDVI) demonstraram alta sensibilidade às condições de pluviosidade, com retração em 2018 e recuperação parcial em 2021. Em contrapartida, a classificação kNN quantificou o avanço contínuo da área urbana, que quase dobrou no período, passando de 25,65% para 35,62% do território, consolidando-se como o principal e mais persistente vetor de transformação.

O modelo de suscetibilidade, desenvolvido via AHP, corroborou a importância dessas transformações. A análise indicou que o Uso e Cobertura do Solo, a Hipsometria e a Densidade Urbana são, juntos, responsáveis por mais de 81% da suscetibilidade ambiental da área. Isso confirma que a combinação da topografia local com a intensidade da ocupação humana, principalmente a impermeabilização do solo, são os fatores que mais contribuem para a criticidade do território.

Esta pesquisa, portanto, contribui com uma base de dados técnica e quantitativa que pode subsidiar o planejamento territorial e a gestão de riscos em Barreiros. A geração de diagnósticos precisos sobre a dinâmica de LULC e a identificação de áreas críticas são contribuições essenciais para a formulação de políticas públicas alinhadas a um desenvolvimento urbano mais resiliente e sustentável.

Como limitações do estudo, aponta-se a dependência de dados históricos para uma validação mais aprofundada do mapa de suscetibilidade. Para trabalhos futuros, recomenda-se a inclusão de outros fatores condicionantes no modelo AHP, como a declividade do terreno, e a integração com dados de sensores de radar (SAR), que

poderiam refinar a análise. A aplicação de algoritmos de aprendizado profundo (Deep Learning) também se apresenta como uma promissora via de aprimoramento para futuras pesquisas.

A perspectiva é que a metodologia estabelecida neste estudo possa ser aperfeiçoada e aplicada em estudos de casos de outras regiões urbanas com características semelhantes.

REFERÊNCIAS

- ABAZAJ, R. et al. Using Sentinel-2 and Landsat 8 Images to Monitor the Drin River Cascade. **Hydrology**, v. 7, n. 3, p. 53, 2020.
- ABDI, A. M. Land use and land cover classification performance of machine learning algorithms in a boreal landscape using Sentinel-2 data. **GIScience & Remote Sensing**, v. 56, n. 7, p. 1059-1079, 2019.
- ABDI, A. M. Comparison of supervised classification techniques for mapping land use and land cover in a sub-tropical region. **Geodesy and Cartography**, v. 48, n. 1, p. 1-13, 2022.
- ALBERTINI, C. et al. A review of optical satellite remote sensing for water extent and flood monitoring. **Remote Sensing**, v. 14, n. 21, p. 5569, 2022.
- ALI, A. M. et al. The effects of urbanization on runoff characteristics. **Modern Applied Science**, v. 5, n. 6, p. 131, 2011.
- ALVARES, C. A. et al. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711-728, 2013.
- ALVES, E. D. L. **Análise de frequência de inundações em bacias hidrográficas com escassez de dados: o caso da bacia do rio Una-PE**. 2017. Dissertação (Mestrado em Engenharia Civil e Ambiental) – Universidade Federal de Pernambuco, Caruaru, 2017.
- ALVES, E. D. L. **Análise de frequência de cheias graduada por eventos históricos em bacias hidrográficas com escassez de dados**. 2022. Tese (Doutorado em Engenharia Civil e Ambiental) – Universidade Federal de Pernambuco, Caruaru, 2022.
- ALVES, I. C. et al. Análise de resiliência a desastres naturais em municípios da bacia hidrográfica do Rio Una, Pernambuco, Brasil. **Desenvolvimento e Meio Ambiente**, v. 64, 2024.
- ANDRADE, A. C. S. de et al. Monitoring Land Use and Land Cover in the Brazilian Cerrado Based on the MapBiomas Project: A Case Study of the Uberaba River Basin. **Land**, v. 13, n. 1, p. 110, 2024.
- ANIK, A. R. et al. Analysis of Rainfall and Temperature Variability and Its Impact on Vegetation Dynamics in the Haor Region of Bangladesh. **Climate**, v. 11, n. 9, p. 177, 2023.
- APAC. **Relatório de situação de recursos hídricos do Estado de Pernambuco 2011/2012**. Recife, 2013. Disponível em: <https://www.lai.pe.gov.br/apac/wp-content/uploads/sites/9/2019/03/Relat%C3%B3rio-de-situa%C3%A7%C3%A3o-de-recursos-h%C3%ADricos-do-Estado-de-Pernambuco-APAC-2011-2012.pdf>. Acesso em: 5 fev. 2024.
- APAC. **Atlas Climatológico do Estado de Pernambuco: normais climatológicas 1991-2020**. Recife, 2023. Disponível em:

<https://www.apac.pe.gov.br/images/webAtlas-Climatologico-do-Estado-de-Pernambuco-APAC.pdf>. Acesso em: 5 fev. 2024.

ATEFI, B.; MIURA, T. Monitoring temporal changes of land cover types in Hawaii using landsat time series data. **Geographies**, v. 2, n. 1, p. 15-32, 2022.

BANTCHINA, M.; GÜNDOĞDU, A. Comparative Analysis of Machine Learning and Deep Learning Models for Crop Type Classification Using Sentinel-2 Imagery. **Agriculture**, v. 14, n. 2, p. 289, 2024.

BERA, A. et al. Application of AHP and GIS for the assessment of flood-prone zones in the upper catchment of the Kangsabati river. **Geomatics, Natural Hazards and Risk**, v. 10, n. 1, p. 1876-1896, 2019.

BEZERRA, T. N. et al. Comportamento do Índice de Vegetação (NDVI) na Bacia Hidrográfica do Rio Brígida – PE. *In*: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 18., 2018, Santos. **Anais...** São José dos Campos: INPE, 2018. p. 117-120.

BHATTI, S. S.; TRIPATHI, N. K. Built-up area extraction using Landsat 8 OLI imagery. **GIScience & Remote Sensing**, v. 51, n. 4, p. 445-467, 2014.

BOKHARI, S. H. A. et al. Flood susceptibility assessment of the Jhelum district, Pakistan using GIS-based AHP method. **GeoJournal**, v. 89, n. 1, p. 21, 2024.

CARNEIRO, T. et al. Performance analysis of Google Colaboratory as a tool for accelerating deep learning applications. **IEEE Access**, v. 6, p. 61677-61685, 2018.

CHAI, J. et al. A review on the analytic hierarchy process. **International Journal of Information Technology & Decision Making**, v. 12, n. 02, p. 235-263, 2013.

COHEN, B. Urbanization in developing countries: Current trends, future projections, and key challenges for sustainability. **Technology in Society**, v. 28, n. 1-2, p. 63-80, 2006.

COLLINS, M. G.; STEINER, F. R.; RUSHMAN, M. J. Land-use suitability analysis in the United States: historical development and promising technological achievements. **Environmental Management**, v. 28, p. 611-621, 2001.

COLUSSI, I. L. et al. Desempenho e características agrônômicas de cultivares de soja em diferentes ambientes e épocas de semeadura. **Revista de Ciências Agrárias**, v. 46, p. e11296, 2023.

CONGEDO, L. **Semi-automatic classification plugin documentation**. Roma: Sapienza University of Rome, 2021.

CUI, L. et al. Vegetation dynamic responses to climate change in the Three-River Headwaters region of the Tibetan Plateau. **Scientific Reports**, v. 9, n. 1, p. 1828, 2019.

CUNNINGHAM, P.; DELANY, S. J. k-Nearest neighbour classifiers-a tutorial. **ACM Computing Surveys (CSUR)**, v. 54, n. 6, p. 1-25, 2021.

DARKO, A. et al. A review of the application of analytic hierarchy process (AHP) in construction. **International Journal of Construction Management**, v. 19, n. 5, p. 436-452, 2019.

DE LUCENA, J. et al. Eventos extremos de lluvia y riesgo hidroclimático en zona de La Mata - Pernambuco/Brasil. **Investigaciones Geográficas**, n. 51, p. 81-90, 2016.

DELGADILLO-HERRERA, G. J. et al. A methodology for estimating surface urban heat island through spectral indices and land cover in a semi-arid city. **Revista de Teledetección**, n. 54, p. 69-82, 2019.

DODANGEH, E. et al. Short-term and long-term urban flood prediction using a hybrid statistical-conceptual model. **Journal of Hydrology**, v. 589, p. 125150, 2020.

DOTTO, B. R. et al. Suscetibilidade morfométrica à erosão na bacia hidrográfica do Ribeirão do Ouro/SP. **Revista Brasileira de Geomorfologia**, v. 24, n. 2, 2023.

DU, Y. et al. Water bodies' mapping from Sentinel-2 imagery with modified normalized difference water index at 10-m spatial resolution produced by sharpening the SWIR band. **Remote Sensing**, v. 8, n. 4, p. 354, 2016.

DUARTE, L. M. G. et al. R, Python, and QGIS: an open-source geoprocessing pipeline for biodiversity data. **Ecography**, v. 44, n. 10, p. 1478-1487, 2021.

DUTTA, D. et al. Monitoring of land use/land cover changes in the Manas National Park, a world heritage site. **Geocarto International**, v. 32, n. 8, p. 891-905, 2017.

ESA. **The Sentinel missions**. 2014. Disponível em: https://www.esa.int/Applications/Observing_the_Earth/Copernicus/The_Sentinel_missions. Acesso em: 15 dez. 2023.

ESA. **The story of Sentinel-2**. ESA Bulletin, n. 161, 2015. Disponível em: https://www.esa.int/About_Us/ESA_Publications/ESA_Bulletin_161_1st_quarter_2015. Acesso em: 15 dez. 2023.

ESA. **Sentinel-2 Products Specification Document**. 2024. Disponível em: <https://sentiwiki.copernicus.eu/display/S2/S2-PDGS-CS-DI-PSD+-+S2+Product+Specification+Document>. Acesso em: 15 dez. 2023.

FABIAN, P. S. et al. Modeling, challenges, and strategies for understanding impacts of climate extremes (droughts and floods) on water quality in Asia: a review. **Environmental Research**, v. 225, p. 115617, 2023.

FARHADI, H. et al. Flood risk assessment for the Gorganrood river basin, Iran, using geographically weighted regression. **Geomatics, Natural Hazards and Risk**, v. 13, n. 1, p. 57-81, 2022.

FENTA, A. A. et al. The dynamics of urban expansion and land use/land cover changes using remote sensing and spatial metrics: the case of Mekelle City of northern Ethiopia. **International Journal of Remote Sensing**, v. 38, n. 14, p. 4107-4129, 2017.

- FIX, E.; HODGES JR., J. L. **Discriminatory analysis-nonparametric discrimination: consistency properties**. Randolph Field: USAF School of Aviation Medicine, 1951. Report Number 4.
- FLENNIKEN, M. W. et al. Assessing QGIS for use in introductory undergraduate GIS courses. **Journal of Geographical Systems**, v. 22, p. 131-144, 2020.
- FRANCO-LOPES, H. **Caracterização e Mapeamento de Tipologias Florestais na Amazônia Brasileira**. 2001. Tese (Doutorado) – Universidade de Lisboa, Lisboa, 2001.
- GARCIA-ALVAREZ, D. et al. Open-source tools for the automatic generation of land use maps based on remote sensing imagery. **Remote Sensing**, v. 14, n. 11, p. 2598, 2022.
- GÉRON, A. **Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow**. 3. ed. O'Reilly Media, 2023.
- GOEPEL, K. D. Implementation of an online software tool for the analytic hierarchy process (AHP-OS). **International Journal of the Analytic Hierarchy Process**, v. 10, n. 3, 2018.
- GOWARD, S. N. et al. Normalized difference vegetation index measurements from the advanced very high resolution radiometer. **Remote Sensing of Environment**, v. 35, n. 2-3, p. 257-277, 1991.
- GRIMM, N. B. et al. Global change and the ecology of cities. **Science**, v. 319, n. 5864, p. 756-760, 2008.
- GUIMARÃES, E. M. **A geodiversidade como subsídio ao geoturismo e geoconservação no município de Barreiros, Pernambuco**. 2016. Monografia (Graduação em Geografia) - Universidade Federal de Pernambuco, Recife, 2016.
- GUNTARA, A. The use of Google Colaboratory for science and education: a review of the literature. **Jurnal Pendidikan MIPA**, v. 24, n. 2, p. 288-299, 2023.
- HASHIM, H. et al. Monitoring of land use/land cover changes and its linkage with land surface temperature in Multan city, Pakistan, using remote sensing and GIS techniques. **Environmental Science and Pollution Research**, v. 30, n. 10, p. 27361-27376, 2023.
- HAZIR, M. H. M. et al. Comparative study of NDWI, MNDWI, and AWEI for extracting water features and assessing flood damage. *In*: IOP CONFERENCE SERIES: EARTH AND ENVIRONMENTAL SCIENCE, 2016. **Anais...** IOP Publishing, 2016. v. 37, n. 1, p. 012028.
- HE, C.; SHI, P.; XIE, D.; ZHAO, Y. Improving the normalized difference built-up index to map urban built-up areas using a semiautomatic segmentation approach. **Remote Sensing Letters**, v. 1, n. 4, p. 213–221, 2010.
- HIRYE, S. et al. Analysis of landslide susceptibility zonation mapping using AHP method in part of Western Ghats, India. **Environmental Monitoring and Assessment**, v. 195, n. 6, p. 741, 2023.

HUSSEIN, H. et al. Urbanization and land use change in the greater Toronto area: a study of the impacts of urban sprawl on agricultural lands. **Journal of Urban Management**, v. 7, n. 2, p. 81-91, 2018.

IBGE. **Cidades e Estados: Barreiros**. Rio de Janeiro, 2022. Disponível em: <https://www.ibge.gov.br/cidades-e-estados/pe/barreiros.html>. Acesso em: 7 mai. 2024.

IPCC. **Climate Change 2022: Impacts, Adaptation and Vulnerability**. Contribution of Working Group II to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge: Cambridge University Press, 2022.

JAVED, A. et al. Review of Spectral Indices for Urban Remote Sensing. **Photogrammetric Engineering & Remote Sensing**, v. 87, n. 7, p. 513–524, 2021.

Jl, L.; PETERS, A. J. Assessing vegetation response to drought in the northern Great Plains using vegetation and drought indices. **Rangeland Ecology & Management**, v. 56, n. 5, p. 451-458, 2003.

JOHARY, F. S. et al. A review of Google Colaboratory for remote sensing and gis applications. **International Journal of Geoinformatics**, v. 19, n. 2, p. 1-12, 2023.

KAUR, A.; PANDEY, P. C. A review on built-up area extraction using remote sensing techniques. **Geocarto International**, v. 37, n. 26, p. 8632-8656, 2022.

KHADDARI, B. et al. Flood susceptibility mapping in the Ourika watershed (Morocco) using AHP method and GIS. **Geomatics, Natural Hazards and Risk**, v. 14, n. 1, p. 2162638, 2023.

KOTARBA, A.Z.; ALEKSANDROWICZ, S. Impervious surface detection with nighttime photography from the International Space Station. **Remote Sensing of Environment**, v. 176, p. 295–307, 2016.

KUSUMA, C. P. B. et al. Comparison of several supervised classification algorithms for land cover mapping using Sentinel-2 imagery. **IOP Conference Series: Earth and Environmental Science**, v. 1145, n. 1, p. 012041, 2023.

LANDIS, J. R.; KOCH, G. G. The measurement of observer agreement for categorical data. **Biometrics**, p. 159-174, 1977.

LAONAMSAI, S. et al. Time-series analysis of land use and land cover changes using landsat imagery and spectral indices. **Geosciences**, v. 13, n. 8, p. 240, 2023.

LARONDELLE, N.; STROHBACH, M. W. A framework for assessing the supply and demand of urban ecosystem services. **Ecological Indicators**, v. 40, p. 28-36, 2014.

LEAL, G. A. P. **Análise geoambiental e áreas de suscetibilidade à erosão hídrica na bacia hidrográfica do córrego Rico, Jaboticabal-SP**. 2017. Monografia (Graduação em Engenharia Agrônômica) – Universidade Estadual Paulista “Júlio de Mesquita Filho”, Jaboticabal, 2017.

- LEAL, G. A. P. **Modelagem da fragilidade ambiental da bacia hidrográfica do Rio Pardo/SP, utilizando geotecnologias**. 2019. Dissertação (Mestrado em Agronomia) - Universidade Estadual Paulista "Júlio de Mesquita Filho", Jaboticabal, 2019.
- LEFULEBE, B. E.; VAN DER WALT, A. J.; XULU, S. Classification of Urban Land Use and Land Cover with K-Nearest Neighbour Classifier in the City of Cape Town, South Africa - Cape Flats Case Study. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. XLVIII-1/W2-2023, p. 967-974, 2023.
- LIMA, F. V. M. S. et al. Multi-sensor geodetic observations for drought characterization in the Northeast Atlantic Eastern Hydrographic Region, Brazil. **Science of The Total Environment**, v. 846, p. 157426, 2022.
- LIMA, G. F. **Mapeamento de áreas de risco a inundação e alagamento no município de Belém-PA**. 2024. Trabalho de Conclusão de Curso (Graduação em Engenharia Ambiental e Sanitária) - Universidade da Amazônia, Belém, 2024.
- LIU, S.; LIU, R.; TAN, N. A spatial improved-kNN-based flood inundation risk framework for urban tourism under two rainfall scenarios. **Sustainability**, v. 13, n. 5, p. 2859, 2021.
- LIU, X. et al. New normalized difference index for built-up land enhancement using airborne visible infrared imaging spectrometer imagery. **Journal of Applied Remote Sensing**, v. 8, n. 1, p. 085092, 2014.
- LONDE, L. R. et al. Impactos de desastres socioambientais em saúde pública: estudos dos casos dos estados de Santa Catarina em 2008 e Pernambuco em 2010. **Revista Brasileira de Estudos de População**, v. 32, n. 3, p. 537-562, 2015.
- LUBIS, A. R.; LUBIS, M.; AL-KHOWARIZMI. Optimization of distance formula in K-Nearest Neighbor method. **Bulletin of Electrical Engineering and Informatics**, v. 9, n. 1, p. 326-338, 2020.
- MADZÍK, P; FALÁT, L. State-of-the-art on analytic hierarchy process in the last 40 years: Literature review based on Latent Dirichlet Allocation topic modelling. **PLoS One**, v. 17, n. 5, p. e0268777, 2022.
- MAS, J. F. et al. Land use/land cover change detection combining automatic processing and visual interpretation. **European Journal of Remote Sensing**, v. 50, n. 1, p. 626-635, 2017.
- MCFEETERS, S. K. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. **International journal of remote sensing**, v. 17, n. 7, p. 1425-1432, 1996.
- MFONDOUM, A. H. N. et al. Improving the land surface general drought index model. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 42, p. 101-108, 2020.

MONIRUZZAMAN, M. et al. Decadal Urban Land Use/Land Cover Changes and Its Impact on Surface Runoff Potential for the Dhaka City and Surroundings Using Remote Sensing. **Remote Sensing**, v. 13, n. 1, p. 83, 2020.

MONTERO, D. et al. A standardized catalogue of spectral indices to advance the use of remote sensing in earth system research. **Scientific Data**, v. 10, n. 1, p. 197, 2023.

NGUYEN, C. et al. A Modified Bare Soil Index to Identify Bare Land Features during Agricultural Fallow-Period in Southeast Asia Using Landsat 8. **Land**, v. 10, n. 3, p. 231, 2021.

OLOFSSON, P. et al. Good practices for estimating area and assessing accuracy of land change. **Remote Sensing of Environment**, v. 148, p. 42-57, 2014.

PAN, X.; LUO, Y.; XU, Y. K-nearest neighbor based structural twin support vector machine. **Knowledge-Based Systems**, v. 88, p. 34-44, 2015.

PAN, F.; XI, X.; WANG, C. A comparative study of water indexes and image classification algorithms for mapping inland surface water bodies using Landsat imagery. **Preprints**, 2019.

PEDREGOSA, F. et al. Scikit-learn: Machine learning in Python. **Journal of machine learning research**, v. 12, p. 2825-2830, 2011.

PEI, F.; ZHOU, Y.; XIA, Y. Application of Normalized Difference Vegetation Index (NDVI) for the Detection of Extreme Precipitation Change. **Forests**, v. 12, n. 5, p. 594, 2021.

PEREIRA, G. W. et al. Smart-Map: An Open-Source QGIS Plugin for Digital Mapping Using Machine Learning Techniques and Ordinary Kriging. **Agronomy**, v. 12, n. 6, p. 1350, 2022.

PHIRI, D. et al. Sentinel-2 Data for Land Cover/Use Mapping: A Review. **Remote Sensing**, v. 12, n. 14, p. 2291, 2020.

PRASAD, A. et al. Remote sensing satellite data and spectral indices: an initial evaluation for the sustainable development of an urban area. **Sustainable Water Resources Management**, v. 8, n. 1, p. 19, 2022.

RABBY, Y. W.; HOSSAIN, M. B.; ABEDIN, J. Landslide susceptibility mapping in three Upazilas of Rangamati hill district Bangladesh: application and comparison of GIS-based machine learning methods. **Geocarto International**, v. 37, n. 12, p. 3371–3396, 2022.

RAHMAN, M. S.; SENKBEIL, J. C.; KEELLINGS, D. J. Spatial and Temporal Variability of Extreme Precipitation Events in the Southeastern United States. **Atmosphere**, v. 14, n. 8, p. 1301, 2023.

RANJAM, A.; SINGH, R. Comparative analysis of distance metrics on k-NN algorithm. *In: 2019 INTERNATIONAL CONFERENCE ON AUTOMATION, COMPUTATIONAL AND TECHNOLOGY MANAGEMENT (ICACTM)*. **Anais... IEEE**, 2019. p. 304-307.

RASUL, A. et al. Applying Built-Up and Bare-Soil Indices from Landsat 8 to Cities in Dry Climates. **Land**, v. 7, n. 3, p. 81, 2018.

REN, J. et al. A Novel Hybrid Extreme Learning Machine Approach Improved by K Nearest Neighbor Method and Fireworks Algorithm for Flood Forecasting in Medium and Small Watershed of Loess Region. **Water**, v. 11, n. 9, p. 1848, 2019.

ROSAS-CHAVOYA, M. et al. QGIS a constantly growing free and open-source geospatial software contributing to scientific development. **Cuadernos de Investigación Geográfica**, v. 48, n. 1, p. 197–213, 2022.

ROUSE, J. W. et al. **Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation**. Greenbelt: NASA/GSFC, 1974. Type C, III.

RUKUNDO, E.; DOĞAN, A. Assessment of Climate and Land Use Change Projections and their Impacts on Flooding. **Polish Journal of Environmental Studies**, v. 25, n. 6, 2016.

SAATY, T. L. The analytic hierarchy process—what it is and how it is used. **Mathematical Modelling**, v. 9, n. 3-5, p. 161-176, 1987.

SAATY, T. L. **The analytic hierarchy process: planning, priority setting, resource allocation**. New York: McGraw-Hill, 1980. Republicado por RWS Publications, Pittsburgh, 1990.

SALAS, E.; KUMARAN, S. Hyperspectral Bare Soil Index (HBSI): Mapping Soil Using an Ensemble of Spectral Indices in Machine Learning Environment. **Land**, v. 12, n. 7, p. 1375, 2023.

SANTIAGO, E. J. P. et al. Mathematical model for handling in precision fertigation. **Research, Society and Development**, v. 9, n. 6, p. e175963530, 2020.

SAPENA, M.; RUIZ, L. A. Analysis of land use/land cover spatio-temporal metrics and population dynamics for urban growth characterization. **Computers, Environment and Urban Systems**, v. 73, p. 27-39, 2019.

SCHNEIDER, A. et al. A new urban landscape dataset for the 21st century. **Remote Sensing**, v. 8, n. 8, p. 655, 2016.

SELVAM, R. A.; ANTONY JEBAMALAI, A. R. Application of the analytical hierarchy process (AHP) for flood susceptibility mapping using GIS techniques in Thamirabarani river basin, Srivaikundam region, Southern India. **Natural Hazards**, v. 118, p. 1065–1083, 2023.

SHIRMARD, H. et al. A review of machine learning in processing remote sensing data for mineral exploration. **Remote Sensing of Environment**, v. 268, p. 112750, 2022.

SOLTANIAN, F. K. et al. Flood monitoring using NDWI and MNDWI spectral indices: a case study of Aghqala Flood-2019, Golestan Province, Iran. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. XLII-4/W18, p. 653-657, 2019.

- SOMANATHAN, S. et al. A Novel Bare Soil Index for Enhancing the Mapping of Bare Soil Area – An Indicator of Urban Expansion. **Ecological Engineering & Environmental Technology**, v. 25, n. 4, p. 162-171, 2024.
- SOUZA, G. G. et al. Mapping of impermeable surfaces in Western Bahia using Machine Learning Algorithm. **Revista de Geociências do Nordeste**, v. 10, n. 2, p. 141-158, 2024.
- STOYANOVA, M. Application of Sentinel-2 data for post-disaster land cover monitoring. **Aerospace Research in Bulgaria**, v. 35, p. 219-232, 2023.
- SU, S. et al. An Impervious Surface Spectral Index on Multispectral Imagery Using Visible and Near-Infrared Bands. **Remote Sensing**, v. 14, n. 14, p. 3391, 2022.
- TALUKDAR, S. et al. Land-Use Land-Cover Classification by Machine Learning Classifiers for Satellite Observations—A Review. **Remote Sensing**, v. 12, n. 7, p. 1135, 2020.
- TAN, Z. et al. Influences of climate extremes on NDVI (normalized difference vegetation index) in the Poyang Lake Basin, China. **Wetlands**, v. 35, p. 1033–1042, 2015.
- TAVANA, M.; GHORABA, M. E.; KASHEF, R. A new version of the AHP-express for simplifying the preference elicitation process in the analytic hierarchy process. **Journal of the Operational Research Society**, v. 72, n. 8, p. 1876-1890, 2021.
- TITTI, G.; BARBA, S.; MODONI, G. A QGIS plugin for slope units-based landslide susceptibility analyses. **Geomatics**, v. 2, n. 3, p. 282-300, 2022.
- TOCK, R. **Google Colaboratory**. New York: Columbia University, 2019.
- VARUN, G.; NISHA, R. Knowledge Discovery from Database Using an Integration of Clustering and Classification. **International Journal of Advanced Computer Science and Applications**, v. 2, n. 3, 2011.
- VAUDOUR, E. et al. Temporal mosaicking approaches of Sentinel-2 images for extending topsoil organic carbon content mapping in croplands. **International Journal of Applied Earth Observation and Geoinformation**, v. 96, p. 102277, 2021.
- WALEGA, A. et al. Influence of Changes of Catchment Permeability and Frequency of Rainfall on Critical Storm Duration in an Urbanized Catchment—A Case Study, Cracow, Poland. **Water**, v. 11, n. 12, p. 2557, 2019.
- WANG, Q. et al. Estimation of vegetation traits with kernel NDVI. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 195, p. 408–417, 2023.
- WEISS, M. C.; PIPPI, L. G. Análise da fragilidade ambiental na bacia hidrográfica do arroio Jaquirana-RS, Brasil. **Revista do Departamento de Geografia**, v. 37, p. 153-167, 2019.
- WIATKOWSKA, B.; SŁODCZYK, J.; STOKOWSKA, A. Spatial-Temporal Land Use and Land Cover Changes in Urban Areas Using Remote Sensing Images and GIS Analysis: The Case Study of Opole, Poland. **Geosciences**, v. 11, n. 8, p. 312, 2021.

- WILSON, J.; CHAKRABORTY, A. **The suburban strange: new explorations in landscape, identity, and politics**. Ann Arbor: University of Michigan Press, 2013.
- WU, Z.; SHEN, Y.; WANG, H.; WU, M. Urban flood disaster risk evaluation based on ontology and Bayesian Network. **Journal of Hydrology**, v. 583, p. 124596, 2020.
- XU, D. et al. Real-time road traffic state prediction based on kernel-kNN. **Transportation research part C: emerging technologies**, v. 92, p. 104-118, 2018.
- XU, H. Modification of normalized difference water index (NDWI) to enhance open water features in remotely sensed imagery. **International journal of remote sensing**, v. 27, n. 14, p. 3025-3033, 2006.
- ZAFAR, Z. et al. Predictive modeling of regional carbon storage dynamics in response to land use/land cover changes: an InVEST-based analysis. **Ecological Informatics**, v. 82, p. 102701, 2024.
- ZHA, Y.; GAO, J.; NI, S. Use of normalized difference built-up index in automatically mapping urban areas from TM imagery. **International Journal of Remote Sensing**, v. 24, n. 3, p. 583–594, 2003.
- ZHANG, C.; XU, T.; WANG, T.; ZHAO, Y. Spatial-temporal evolution of influencing mechanism of urban flooding in the Guangdong Hong Kong Macao greater bay area, China. **Frontiers in Earth Science**, v. 10, p. 1113997, 2023.
- ZHANG, T.; TANG, H. Built-up area extraction from Landsat 8 images using convolutional neural networks with massive automatically selected samples. *In*: LAI, J. H. et al. (ed.). **Pattern recognition and computer vision**. Cham: Springer, 2018. p. 445-456. (Lecture Notes in Computer Science, v. 11257).
- ZHANG, S. et al. A review of neighborhood-based classifiers. **Information Fusion**, v. 47, p. 11-23, 2019.
- ZHAO, G. et al. Assessment of urban flood susceptibility using semi-supervised machine learning model. **Science of The Total Environment**, v. 659, p. 940-949, 2019.
- ZOPE, P. E.; ELDHO, T. I.; JOTHIPRAKASH, V. Impacts of land use–land cover change and urbanization on flooding: A case study of Oshiwara River Basin in Mumbai, India. **Catena**, v. 145, p. 142-154, 2016.