

**UNIVERSIDADE FEDERAL DE ALAGOAS – UFAL
CAMPUS DE ENGENHARIAS E CIÊNCIAS AGRÁRIAS – CECA
ENGENHARIA DE AGRIMENSURA E CARTOGRÁFICA**

NYKOLAS DANIEL PEREIRA DA SILVA

**MAPEAMENTO DA COBERTURA E USO DA TERRA E DA VEGETAÇÃO
ARBÓREA UTILIZANDO DADOS ESPECTRAIS E TOPOGRÁFICOS DO PE3D NA
REGIÃO METROPOLITANA DO RECIFE-PE**

Rio Largo
2026

NYKOLAS DANIEL PEREIRA DA SILVA

**MAPEAMENTO DA COBERTURA E USO DA TERRA E DA VEGETAÇÃO
ARBÓREA UTILIZANDO DADOS ESPECTRAIS E TOPOGRÁFICOS DO PE3D NA
REGIÃO METROPOLITANA DO RECIFE-PE**

Trabalho de Conclusão de Curso, para
obtenção de título de Bacharel em
Engenharia de Agrimensura, pelo
Campus de Engenharias e Ciências
Agrárias da Universidade Federal de
Alagoas.

Orientador: Prof.º Dr. Jhonathan Gomes
dos Santos.

Catálogo na Fonte
Universidade Federal de Alagoas
Biblioteca Campus de Engenharias Ciências Agrárias
Bibliotecário Responsável: Stefano João dos Santos

S586m Silva, Nykolas Daniel Pereira da

Mapeamento da cobertura e uso da terra e da vegetação arbórea utilizando dados espectrais e topográficos do pe3d na região metropolitana do Recife-PE/ Nykolas Daniel Pereira da Silva. – Rio Largo - Al, 2026.

92 f. : il.

Trabalho de Conclusão de Curso (Graduação em Engenharia de Agrimensura,) Universidade Federal de Alagoas, Campus Ceca – Rio largo, 2026.

Orientador: Prof.o Dr. Jhonathan Gomes dos Santos.

1 Classificação supervisionada; Aprendizado de máquina; PE3D; Uso e cobertura da terra;

CDU: 631.95

Folha de Aprovação

NYKOLAS DANIEL PEREIRA DA SILVA
MAPEAMENTO DA COBERTURA E USO DA TERRA E DA VEGETAÇÃO ARBÓREA
UTILIZANDO DADOS ESPECTRAIS E TOPOGRÁFICOS DO PE3D NA REGIÃO
METROPOLITANA DO RECIFE-PE.

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação de Engenharia de Agrimensura da Universidade Federal de Alagoas, como requisito para obtenção do Título de Bacharel em Engenharia de Agrimensura.

Aprovado em: 26/06/2026

Banca Examinadora:

Documento assinado digitalmente
 **JHONATHAN GOMES DOS SANTOS**
Data: 03/07/2026 09:21:38-0300
Verifique em <https://validar.iti.gov.br>

(Prof. Dr. Jhonathan Gomes dos Santos, Universidade Federal de Alagoas) (Orientador)

Documento assinado digitalmente
 **MICHELLE ADELINO CERQUEIRA**
Data: 03/07/2026 12:20:10-0300
Verifique em <https://validar.iti.gov.br>

(Prof^ª. Dra. Michelle Adelino Cerqueira, Universidade Federal de Alagoas)

(Eng. Bianca Maria Lima Cruz Pereira, Universidade Federal de Alagoas)

Dedico

In memoriam a Aristóteles Alves da Silva
(meu avô paterno), uma das pessoas que
mais me encorajou e incentivou durante
essa jornada. Te amarei para sempre.

AGRADECIMENTOS

Agradeço, primeiramente, a toda a minha família por todo o apoio e incentivo para que eu pudesse concluir esta importante etapa. Obrigado por estarem ao meu lado no momento mais difícil da minha trajetória: a perda do meu avô durante o desenvolvimento deste TCC. O amparo de vocês foi fundamental para que eu encontrasse forças para seguir adiante e finalizar este trabalho.

Agradeço imensamente à minha mãe, por sempre me apoiar de todas as formas — emocional e financeiramente — e por seus conselhos sábios em cada etapa da faculdade.

Ao meu pai, pelo apoio incondicional e por caminhar ao meu lado durante todo o período da graduação, desde o dia da inscrição no curso até este momento do encerramento.

Aos meus irmãos, com um carinho especial à minha irmã, Nykole, pessoa com quem dividi conquistas, sonhos e momentos inesquecíveis. E também ao meu caçula, William, que trouxe ainda mais alegria aos meus dias.

A todos os meus primos, especialmente ao Antony William, Engenheiro Agrimensor, cujo conselho me guiou para este curso com o qual tanto me identifiquei. Ao Lucas, também, por estar comigo durante todo esse processo.

Aos meus amigos de graduação e de estágio — Gabriel Carneiro, Sandy, Gustavo Camilo, Gustavo Lima, Vitória, Eduardo, Jessilanny, João Ribeiro e Welvis —, por tornarem essa jornada muito mais leve e descontraída.

A todos os professores do curso de Engenharia de Agrimensura, pelo vasto conhecimento técnico e científico compartilhado. Em especial, ao Professor Jhonathan, por sempre me motivar a ir além e a buscar o meu melhor. Às professoras Juciela e Rafaella, por transcenderem os ensinamentos da sala de aula e pelos puxões de orelha nos momentos certos.

Por fim, à minha noiva, Victória Cássia, dedico o agradecimento mais especial. Ela foi a pessoa que acompanhou de perto cada detalhe dessa jornada, apoiando-me de todas as formas possíveis para que este sonho se tornasse realidade. Obrigado por não me deixar desistir, por me inspirar a persistir e por sempre desejar o melhor para mim.

RESUMO

O mapeamento da cobertura e uso da terra e da vegetação arbórea é fundamental para subsidiar ações de planejamento territorial, monitoramento ambiental e gestão urbana. Entretanto, a elevada complexidade das paisagens urbanas e a semelhança espectral entre diferentes classes tornam a classificação de imagens de sensoriamento remoto um desafio, exigindo o emprego de métodos capazes de integrar diferentes tipos de informações. Nesse contexto, este estudo avaliou o desempenho de algoritmos de aprendizado de máquina no mapeamento da cobertura e uso da terra utilizando dados do Projeto Pernambuco Tridimensional (PE3D). Foram empregados atributos espectrais (RGB e IHS) e topográficos (MDT, nDSM e declividade) derivados de imagens de altíssima resolução espacial na região entre os municípios de Recife, Camaragibe, Olinda, Paulista e São Lourenço da Mata, Pernambuco. As classificações supervisionadas foram realizadas no QGIS por meio do plugin DZetsaka, utilizando os algoritmos Gaussian Mixture Model (GMM), Random Forest (RF) e Extra Trees (ET). Diferentes cenários de classificação foram comparados para analisar a contribuição dos atributos espectrais e topográficos no desempenho dos modelos. Além da classificação multiclasse de cobertura e uso da terra, foi realizado o mapeamento de Vegetação de Grande Porte e Não Vegetação de Grande Porte, com o objetivo de identificar árvores urbanas e remanescentes de florestas urbanas. Os resultados demonstraram que a integração dos atributos RGB, IHS, MDT, nDSM e declividade proporcionou os melhores resultados de classificação. O algoritmo Extra Trees apresentou o melhor desempenho geral, alcançando precisão de 86,1%, seguido pelo Random Forest (84,9%) e pelo Gaussian Mixture Model (80,6%). Para o mapeamento de Vegetação de Grande Porte, os resultados apresentaram precisões superiores a 97%, evidenciando o potencial das imagens de altíssima resolução espacial para a identificação da cobertura arbórea urbana. Os resultados indicaram ainda que os algoritmos baseados em árvores de decisão apresentaram maior capacidade de discriminar classes com características espectrais e altimétricas semelhantes. Conclui-se, portanto, que a combinação de atributos espectrais e topográficos contribui significativamente para o aprimoramento do mapeamento da cobertura e uso da terra, bem como para a identificação de vegetação arbórea em ambientes urbanos, evidenciando o potencial dos dados do PE3D e dos algoritmos de aprendizado de máquina para aplicações em sensoriamento remoto, planejamento territorial e monitoramento ambiental.

Palavras-chave: Classificação supervisionada; Aprendizado de máquina; PE3D; Uso e cobertura da terra; Vegetação urbana; Sensoriamento remoto.

ABSTRACT

Land cover and land use mapping, as well as urban tree vegetation mapping, are essential for supporting territorial planning, environmental monitoring, and urban management. However, the high complexity of urban landscapes and the spectral similarity among different land cover classes make remote sensing image classification a challenging task, requiring methods capable of integrating multiple sources of information. In this context, this study evaluated the performance of machine learning algorithms for land cover and land use mapping using data from the Pernambuco Tridimensional Project (PE3D). Spectral (RGB and IHS) and topographic (DTM, nDSM, and slope) attributes derived from very high spatial resolution imagery were employed in the region encompassing the municipalities of Recife, Camaragibe, Olinda, Paulista, and São Lourenço da Mata, Pernambuco, Brazil. Supervised classifications were performed in QGIS using the DZetsaka plugin and the Gaussian Mixture Model (GMM), Random Forest (RF), and Extra Trees (ET) algorithms. Different classification scenarios were compared to evaluate the contribution of spectral and topographic attributes to model performance. In addition to the multiclass land cover and land use classification, a binary classification of Tall Vegetation and Non-Tall Vegetation was carried out to identify urban trees and remnants of urban forests. The results showed that the integration of RGB, IHS, DTM, nDSM, and slope attributes provided the best classification performance. The Extra Trees algorithm achieved the highest overall accuracy (86.1%), followed by Random Forest (84.9%) and Gaussian Mixture Model (80.6%). For the Tall Vegetation mapping, overall accuracies above 97% were achieved, demonstrating the potential of very high spatial resolution imagery for urban tree canopy identification. Furthermore, decision tree-based algorithms showed a greater ability to discriminate classes with similar spectral and topographic characteristics. It is therefore concluded that the integration of spectral and topographic attributes significantly improves land cover and land use mapping, as well as the identification of urban tree vegetation, highlighting the potential of PE3D data and machine learning algorithms for remote sensing, territorial planning, and environmental monitoring applications.

Keywords: Supervised Classification; Machine Learning; PE3D; Land Use And Land Cover; Urban Vegetation; Remote Sensing.

LISTA DE FIGURAS

Figura 1: Mapa de localização da área de estudo.

Figura 2: Fluxograma.

Figura 3: Mapa Temático: RGB por meio do algoritmo GMM.

Figura 4: Matriz de Confusão: RGB por meio do algoritmo GMM.

Figura 5: Mapa Temático: RGB por meio do algoritmo RF.

Figura 6: Matriz de Confusão: RGB por meio do algoritmo RF.

Figura 7: Mapa Temático: RGB por meio do algoritmo ET.

Figura 8: Matriz de Confusão: RGB por meio do algoritmo ET.

Figura 9: Mapa Temático: IHS por meio do algoritmo GMM.

Figura 10: Matriz de Confusão: IHS por meio do algoritmo GMM.

Figura 11: Mapa Temático: IHS por meio do algoritmo RF.

Figura 12: Matriz de Confusão: IHS por meio do algoritmo RF.

Figura 13: Mapa Temático: IHS por meio do algoritmo ET.

Figura 14: Matriz de Confusão: IHS por meio do algoritmo ET.

Figura 15: Mapa Temático: MDT, nDSM e Declividade por meio do algoritmo GMM.

Figura 16: Matriz de Confusão RGB, MDT, nDSM e Declividade por meio do algoritmo GMM.

Figura 17: Mapa Temático: MDT, nDSM e Declividade por meio do algoritmo RF.

Figura 18: Matriz de Confusão RGB, MDT, nDSM e Declividade por meio do algoritmo RF.

Figura 19: Mapa Temático: MDT, nDSM e Declividade por meio do algoritmo GMM.

Figura 20: Matriz de Confusão RGB, MDT, nDSM e Declividade por meio do algoritmo ET.

Figura 21: Mapa Temático: RGB, MDT, nDSM e Declividade por meio do algoritmo GMM.

Figura 22: Matriz de Confusão RGB, MDT, nDSM e Declividade por meio do algoritmo GMM.

Figura 23: Mapa Temático: RGB, MDT, nDSM e Declividade por meio do algoritmo RF.

Figura 24: Matriz de Confusão RGB, MDT, nDSM e Declividade por meio do algoritmo RF.

Figura 25: Mapa Temático: RGB, MDT, nDSM e Declividade por meio do algoritmo ET.

Figura 26: Matriz de Confusão RGB, MDT, nDSM e Declividade por meio do algoritmo

ET.

Figura 27: Mapa Temático: RGB, IHS, MDT, nDSM e Declividade por meio do algoritmo GMM.

Figura 28: Matriz de Confusão: RGB, IHS, MDT, nDSM e Declividade por meio do algoritmo GMM.

Figura 29: Mapa Temático: RGB, IHS, MDT, nDSM e Declividade por meio do algoritmo RF.

Figura 30: Matriz de Confusão: RGB, IHS, MDT, nDSM e Declividade por meio do algoritmo RF.

Figura 31: Mapa Temático: RGB, IHS, MDT, nDSM e Declividade por meio do algoritmo ET.

Figura 32: Matriz de Confusão: RGB, IHS, MDT, nDSM e Declividade por meio do algoritmo ET.

Figura 33: Mapa Temático gerado pelas classificações GMM, RF e ET.

Figura 34: Matrizes de confusão dos modelos GMM, RF e ET.

Figura 35: Precisão Global dos modelos GMM, RF e ET.

LISTA DE ABREVIATURAS E SIGLAS

MDS	Modelo Digital da Superfície
MDT	Modelo Digital do Terreno
ET	<i>Extra Trees</i>
GMM	<i>Gaussian Mixture Model</i>
IHS	Intensidade, Matiz e Saturação
LiDAR	<i>Light Detection and Ranging</i>
MDS	Modelo Digital de Superfície
MDT	Modelo Digital de Terreno
nDSM	Modelo Digital de Superfície Normalizado
PE3D	Pernambuco Tridimensional
QGIS	<i>Quantum Geographic Information System</i>
RF	<i>Random Forest</i>
RGB	<i>Red, Green and Blue</i>
SIG	Sistema de Informações Geográficas

SUMÁRIO

1. INTRODUÇÃO.....	10
2. OBJETIVOS.....	11
2.1 Geral.....	12
2.2 Específicos.....	12
3. FUNDAMENTAÇÃO TEÓRICA.....	12
3.1 Sensoriamento Remoto e Mapeamento da Cobertura e Uso da Terra.....	12
3.2 Classificação de Imagens de Sensoriamento Remoto e Aprendizado de Máquina.....	14
3.3 Contribuição de Atributos Espectrais e Topográficos para a Classificação.....	17
3.4 Imagens de Altíssima Resolução Espacial e Aplicações em Ambientes Urbanos.....	19
3.5 Projeto Pernambuco Tridimensional (PE3D).....	21
4. MATERIAS E MÉTODOS.....	22
4.1 Área de Estudo.....	22
4.2 Materiais.....	24
4.3 Métodos.....	25
4.3.1 Procedimentos metodológicos.....	25
4.3.2 Preparação dos dados e normalização do terreno.....	25
4.3.3 Transformação IHS das imagens RGB.....	26
4.3.4 Coleta das amostras de treinamento.....	26
4.3.5 Classificação supervisionada das imagens.....	27
5. RESULTADOS E DISCUSSÃO.....	29
5.1 Classificação utilizando as bandas RGB.....	29
5.1.1 RGB por meio do algoritmo GMM.....	30
5.1.2 RGB por meio do algoritmo RF.....	32
5.1.3 RGB por meio do algoritmo ET.....	35
5.1.4 Comparação entre GMM, RF e ET utilizando o RGB.....	38
5.2 IHS.....	39
5.2.1 IHS por meio do algoritmo GMM.....	39
5.2.2 IHS por meio do algoritmo RF.....	42
5.2.3 IHS por meio do algoritmo ET.....	45
5.2.4 Comparação entre GMM, RF e ET utilizando o empilhamento IHS.....	48
5.3 Classificação do terreno.....	49
5.3.1 MDT, nDSM e Declividade por meio do algoritmo GMM.....	50
5.3.2 MDT, nDSM e Declividade por meio do algoritmo RF.....	52
5.3.3 MDT, nDSM e Declividade por meio do algoritmo ET.....	55
5.3.4 Comparação entre GMM, RF e ET utilizando o empilhamento de MDT, nDSM e declividade.....	58
5.4 RGB e Terreno.....	59
5.4.1 RGB, MDT, nDSM e Declividade por meio do algoritmo GMM.....	60
5.4.2 RGB, MDT, nDSM e Declividade – RF.....	62

5.4.3 RGB, MDT, nDSM e Declividade por meio do algoritmo ET.....	65
5.4.4 Comparação entre GMM, RF e ET utilizando RGB, MDT, nDSM e Declividade.....	68
5.5 RGB, IHS, MDT, nDSM e Declividade.....	70
5.5.1 RGB, IHS, MDT, nDSM e Declividade por meio do algoritmo GMM.....	70
5.5.2 RGB, IHS, MDT, nDSM e Declividade por meio do algoritmo RF.....	73
5.5.3 RGB, IHS, MDT, nDSM e Declividade por meio do algoritmo ET.....	76
5.5.4 Comparação entre GMM, RF e ET utilizando RGB, IHS, MDT, nDSM e Declividade.....	79
5.6 Vegetação de Grande Porte e Não Vegetação de Grande Porte.....	81
6. CONCLUSÕES E RECOMENDAÇÕES.....	84
6.1 Conclusões.....	84
6.2 Recomendações.....	85
REFERÊNCIAS.....	87

1. INTRODUÇÃO

O sensoriamento remoto constitui uma das principais ferramentas para obtenção de informações sobre a superfície terrestre, permitindo a análise, o monitoramento e o mapeamento de fenômenos naturais e antrópicos em diferentes escalas espaciais. O avanço dos sensores aerotransportados e orbitais, aliado ao desenvolvimento de técnicas de processamento digital de imagens, tem ampliado significativamente a capacidade de caracterização da cobertura e do uso da terra, favorecendo aplicações relacionadas ao planejamento urbano, gestão ambiental, agricultura de precisão e monitoramento dos recursos naturais (MENESES; ALMEIDA; SANO, 2012).

Nos últimos anos, a crescente disponibilidade de imagens de altíssima resolução espacial e de produtos derivados de levantamentos aerotransportados tem ampliado as possibilidades de análise da cobertura e uso da terra. Além de proporcionarem elevado nível de detalhamento espacial, esses produtos favorecem a identificação de diferentes classes temáticas e contribuem para a produção de mapeamentos mais precisos (PARK *et al.*, 2022; BEN MILED *et al.*, 2025). A disponibilidade de dados com elevado nível de detalhamento, entretanto, também impõe desafios relacionados à variabilidade espectral dos alvos e à complexidade dos processos de classificação, especialmente em ambientes urbanos, onde diferentes elementos da paisagem frequentemente apresentam respostas espectrais semelhantes.

Nesse contexto, os métodos de classificação supervisionada baseados em aprendizado de máquina têm sido amplamente empregados para extrair informações temáticas de imagens de sensoriamento remoto. Algoritmos como Random Forest, Extra Trees e Gaussian Mixture Model apresentam capacidade de lidar com grandes volumes de dados e de identificar padrões complexos presentes em atributos espectrais e espaciais, tornando-se alternativas promissoras para aplicações em mapeamento temático. Entretanto, o desempenho desses algoritmos está diretamente relacionado às características dos dados utilizados, tornando necessária a investigação de estratégias que integrem diferentes tipos de atributos para aprimorar a qualidade das classificações (MA *et al.*, 2017).

Além das informações espectrais obtidas por imagens RGB e por transformações como o sistema IHS (Intensidade, Matiz e Saturação), estudos recentes demonstram que a incorporação de variáveis topográficas pode aumentar significativamente a qualidade das classificações. Modelos Digitais de Terreno (MDT), Modelos Digitais de Superfície (MDS), modelos normalizados de superfície (nDSM), declividade e outros atributos derivados da

elevação fornecem informações complementares sobre a estrutura vertical dos alvos, auxiliando na diferenciação de classes que apresentam assinaturas espectrais semelhantes. Pesquisas recentes indicam que o nDSM figura entre as variáveis mais relevantes para a classificação de uso e cobertura da terra, contribuindo para ganhos expressivos de acurácia nos modelos de aprendizado de máquina (PARK *et al.*, 2022; AYDIN; SEFERCIK, 2025).

Além do mapeamento da cobertura e uso da terra, a identificação da vegetação arbórea em ambientes urbanos têm adquirido crescente importância devido aos serviços ecossistêmicos proporcionados pelas árvores, como a regulação térmica, a melhoria da qualidade do ar, a redução do escoamento superficial e a conservação da biodiversidade. Nesse contexto, imagens de altíssima resolução espacial associadas a algoritmos de aprendizado de máquina apresentam grande potencial para identificar árvores urbanas e remanescentes florestais, fornecendo informações que subsidiam ações de planejamento urbano e monitoramento ambiental.

Apesar dos avanços observados na literatura, ainda são limitados os estudos que avaliam de forma comparativa o desempenho de diferentes algoritmos de aprendizado de máquina utilizando, de maneira integrada, atributos espectrais e topográficos derivados dos produtos do Projeto Pernambuco Tridimensional (PE3D), especialmente em áreas urbanas complexas da Região Metropolitana do Recife. Dessa forma, torna-se relevante investigar quais algoritmos e combinações de variáveis apresentam melhor desempenho para o mapeamento da cobertura e uso da terra e da vegetação arbórea nesse contexto.

A área compreendida entre os municípios de Recife, Camaragibe, Olinda, Paulista e São Lourenço da Mata, em Pernambuco, apresenta elevada heterogeneidade espacial, reunindo áreas densamente urbanizadas, fragmentos de vegetação, corpos hídricos e diferentes formas de ocupação do solo (GOVERNO DE PERNAMBUCO, [s.d.]). Essa diversidade torna a região adequada para a avaliação do desempenho de diferentes estratégias de classificação supervisionada aplicadas a imagens de altíssima resolução espacial (PARK *et al.*, 2022).

Diante desse contexto, este trabalho tem como objetivo avaliar o desempenho de algoritmos de aprendizado de máquina no mapeamento da cobertura e uso da terra e da vegetação arbórea na Região Metropolitana do Recife, utilizando dados espectrais e topográficos derivados do Projeto Pernambuco Tridimensional (PE3D).

2. OBJETIVOS

2.1 Geral

Este trabalho tem como objetivo avaliar o desempenho dos algoritmos *Gaussian Mixture Model* (GMM), *Random Forest* (RF) e *Extra Trees* (ET) no mapeamento da cobertura e uso da terra, utilizando atributos espectrais e topográficos dados espectrais e topográficos derivados do Projeto Pernambuco Tridimensional (PE3D).

2.2 Específicos

- Comparar o desempenho dos algoritmos *Gaussian Mixture Model* (GMM), *Random Forest* (RF) e *Extra Trees* (ET) na classificação supervisionada da cobertura e uso da terra;
- Avaliar a contribuição dos atributos espectrais (RGB e IHS) e topográficos (MDT, MDS, nDSM e declividade) para o desempenho das classificações;
- Analisar o impacto da utilização isolada e combinada dos atributos espectrais e topográficos nos resultados dos classificadores;
- Identificar a combinação de algoritmo e conjunto de atributos que apresenta o melhor desempenho para o mapeamento da cobertura e uso da terra na área de estudo;
- Realizar o mapeamento de Vegetação de Grande Porte e não Vegetação de Grande Porte, visando identificar árvores urbanas, áreas arborizadas e remanescentes de florestas urbanas.

3. FUNDAMENTAÇÃO TEÓRICA

3.1 Sensoriamento Remoto e Mapeamento da Cobertura e Uso da Terra

O sensoriamento remoto constitui uma das principais tecnologias empregadas para obtenção de informações sobre a superfície terrestre, permitindo a aquisição de dados sem a necessidade de contato físico direto com os objetos ou fenômenos investigados. Seu funcionamento baseia-se na detecção e interpretação da energia eletromagnética refletida ou emitida pelos diferentes alvos presentes na superfície terrestre, possibilitando a extração de informações relacionadas às características físicas, químicas e biológicas dos ambientes naturais e antrópicos (MENESES; ALMEIDA; SANO, 2012).

Nas últimas décadas, os avanços tecnológicos observados no desenvolvimento de sensores orbitais, aerotransportados e embarcados em Veículos Aéreos Não Tripulados (VANTs), aliados à evolução das técnicas de processamento digital de imagens, ampliaram significativamente a disponibilidade de dados geoespaciais de elevada qualidade. Esse cenário favoreceu a expansão das aplicações do sensoriamento remoto em diferentes áreas do conhecimento, incluindo planejamento urbano, monitoramento ambiental, agricultura de precisão, gestão de recursos naturais, monitoramento de desastres e estudos relacionados às mudanças no uso e cobertura da terra (MENESES; ALMEIDA; SANO, 2012; BLASCHKE, 2010).

Entre as diversas aplicações do sensoriamento remoto, destaca-se o mapeamento da cobertura e uso da terra, considerado uma importante ferramenta para compreender a dinâmica da ocupação do território e subsidiar políticas públicas voltadas ao planejamento territorial e à conservação ambiental. Segundo Meneses, Almeida e Sano (2012), os produtos cartográficos derivados de imagens de sensoriamento remoto permitem identificar alterações na paisagem, monitorar processos de expansão urbana, acompanhar a supressão da vegetação, avaliar transformações em áreas agrícolas e fornecer informações estratégicas para a gestão dos recursos naturais.

O aumento da disponibilidade de imagens de alta e altíssima resolução espacial tem proporcionado avanços expressivos na representação da paisagem. Diferentemente das imagens de média resolução, esses produtos permitem identificar elementos urbanos de pequenas dimensões, como edificações individuais, vias, árvores isoladas e corpos hídricos estreitos, ampliando a capacidade de detalhamento dos mapas temáticos produzidos (BLASCHKE, 2010). Essa característica torna as imagens de altíssima resolução especialmente relevantes em estudos desenvolvidos em ambientes urbanos, onde a elevada heterogeneidade espacial exige maior capacidade de discriminação entre diferentes classes.

Entretanto, o aumento da resolução espacial também introduz novos desafios aos processos de classificação. Em imagens de altíssima resolução, objetos pertencentes à mesma classe frequentemente apresentam elevada variabilidade espectral, enquanto diferentes classes podem compartilhar respostas espectrais semelhantes. Esse comportamento reduz a eficiência de métodos tradicionais de classificação baseados exclusivamente em informações espectrais, tornando necessária a incorporação de informações espaciais, texturais e altimétricas capazes de representar de forma mais completa as características da superfície terrestre (BLASCHKE, 2010; MA *et al.*, 2019).

Nesse contexto, a utilização de técnicas de aprendizado de máquina associadas à integração de diferentes tipos de atributos tem se consolidado como uma das principais estratégias para aumentar a precisão dos processos de classificação. Estudos recentes demonstram que a combinação entre informações espectrais, topográficas e espaciais permite reduzir ambiguidades entre classes temáticas e produzir mapas de cobertura e uso da terra mais consistentes, sobretudo em áreas urbanas caracterizadas por elevada complexidade da paisagem (PARK *et al.*, 2022; BEN MILED *et al.*, 2025).

Além do mapeamento da cobertura e uso da terra, o sensoriamento remoto tem assumido papel crescente na identificação da vegetação arbórea em ambientes urbanos. A elevada resolução espacial das imagens atuais possibilita identificar árvores isoladas, corredores verdes e remanescentes florestais urbanos, fornecendo informações relevantes para estudos relacionados ao conforto térmico, à mitigação das ilhas de calor, à qualidade ambiental, à conservação da biodiversidade e ao planejamento das cidades (ROY; BYRNE; PICKERING, 2012; BLASCHKE, 2010; MENESES; ALMEIDA; SANO, 2012). Dessa forma, o desenvolvimento de metodologias capazes de explorar eficientemente os produtos derivados do sensoriamento remoto representa uma importante contribuição para a gestão territorial e ambiental.

Assim, observa-se que a evolução dos sensores, associada ao desenvolvimento de métodos computacionais para processamento e análise de imagens, ampliou significativamente o potencial do sensoriamento remoto para aplicações relacionadas ao mapeamento temático. Nesse cenário, a utilização integrada de imagens de altíssima resolução espacial, atributos espectrais e topográficos e algoritmos de aprendizado de máquina representa uma abordagem promissora para o aprimoramento da classificação da cobertura e uso da terra e da vegetação arbórea em ambientes urbanos (MA *et al.*, 2019; PARK *et al.*, 2022; AYDIN; SEFERCIK, 2025).

3.2 Classificação de Imagens de Sensoriamento Remoto e Aprendizado de Máquina

A classificação de imagens de sensoriamento remoto consiste no processo de atribuição de classes temáticas aos pixels ou objetos presentes em uma imagem, utilizando informações espectrais, espaciais, texturais e contextuais para representar diferentes tipos de cobertura e uso da terra (MENESES; ALMEIDA; SANO, 2012; MA *et al.*, 2019). Esse procedimento constitui uma das principais etapas do processamento digital de imagens, uma vez que permite transformar informações espectrais em produtos cartográficos capazes de

subsidiar estudos ambientais, planejamento territorial, monitoramento urbano e gestão dos recursos naturais.

Tradicionalmente, a classificação de imagens era realizada por meio de métodos estatísticos convencionais, como o classificador de Máxima Verossimilhança (*Maximum Likelihood*), cuja eficiência depende da suposição de distribuição normal dos dados e da separabilidade espectral entre as classes. Entretanto, o aumento da resolução espacial das imagens e da complexidade das paisagens tornou essas abordagens menos eficientes, especialmente em áreas urbanas caracterizadas pela elevada heterogeneidade dos alvos (CAMARGO *et al.*, 2019; MA *et al.*, 2019).

Nesse contexto, os algoritmos de aprendizado de máquina passaram a desempenhar papel de destaque nas aplicações de sensoriamento remoto. Diferentemente dos métodos tradicionais, estes algoritmos apresentam maior capacidade de identificar relações complexas entre as variáveis de entrada, lidar com dados não lineares e processar grandes volumes de informações sem a necessidade de pressupostos estatísticos rigorosos (MA *et al.*, 2019). Segundo Maxwell, Warner e Fang (2018), o emprego dessas técnicas representa uma das principais evoluções recentes no processamento de imagens de sensoriamento remoto, uma vez que possibilita maior flexibilidade na modelagem dos dados e melhor desempenho em cenários caracterizados por elevada complexidade espacial. Essa capacidade tem contribuído para o aumento da precisão dos mapeamentos de cobertura e uso da terra, sobretudo quando são utilizadas imagens de alta e altíssima resolução espacial.

Entre as abordagens disponíveis, os métodos supervisionados destacam-se por utilizarem amostras previamente identificadas para o treinamento dos classificadores. Nessa abordagem, o algoritmo aprende as características espectrais e espaciais de cada classe temática a partir de dados de referência e, posteriormente, utiliza esse conhecimento para classificar os demais elementos da imagem (MENESES; ALMEIDA; SANO, 2012). A qualidade das amostras de treinamento constitui, portanto, um dos principais fatores responsáveis pelo desempenho final dos modelos.

Dentre os algoritmos supervisionados, o *Random Forest* (RF) destaca-se como um dos métodos mais empregados em aplicações de sensoriamento remoto. Proposto por Breiman (2001), o algoritmo baseia-se na construção de um conjunto de árvores de decisão geradas a partir de amostras aleatórias dos dados e de subconjuntos de variáveis. A classificação final é obtida por votação entre as árvores, tornando o método robusto frente à presença de ruídos, dados redundantes e problemas de sobreajuste. Além disso, o RF apresenta elevada capacidade de generalização e reduz sensibilidade à multicolinearidade entre os atributos,

características que explicam sua ampla utilização em estudos de cobertura e uso da terra (BREIMAN, 2001; MA *et al.*, 2019). Belgiu e Drăguț (2016) destacam que o *Random Forest* se consolidou como um dos algoritmos mais utilizados em sensoriamento remoto devido à sua elevada precisão, estabilidade e reduzida necessidade de ajuste de parâmetros, apresentando desempenho consistente em diferentes tipos de sensores, escalas e aplicações. De maneira semelhante, Pelletier, Valero e Inglada (2016) demonstraram que o algoritmo apresenta elevada robustez para o mapeamento da cobertura e uso da terra em imagens de alta resolução, mesmo quando aplicado a grandes áreas e conjuntos de dados complexos.

O algoritmo *Extra Trees* (ET) possui estrutura semelhante ao *Random Forest*, diferenciando-se principalmente pelo maior grau de aleatoriedade empregado durante a construção das árvores de decisão. Enquanto o RF busca selecionar os melhores pontos de divisão entre as variáveis, o ET realiza essas divisões de forma aleatória, reduzindo ainda mais a variância do modelo e aumentando sua capacidade de generalização em determinados conjuntos de dados (GEURTS; ERNST; WEHENKEL, 2006). Diversos estudos têm demonstrado que essa estratégia pode proporcionar ganhos de desempenho em aplicações envolvendo imagens de alta resolução espacial, especialmente quando associada a conjuntos de atributos espectrais e topográficos (SAMAT *et al.*, 2018).

Outro algoritmo amplamente empregado é o *Gaussian Mixture Model* (GMM), modelo probabilístico baseado na representação das distribuições dos dados por meio da combinação de múltiplas distribuições gaussianas. O GMM apresenta vantagens na modelagem de classes com elevada variabilidade interna e na representação de distribuições complexas. Entretanto, seu desempenho pode ser inferior ao de algoritmos baseados em árvores de decisão quando aplicado a conjuntos de dados altamente heterogêneos, nos quais diferentes classes apresentam elevada sobreposição espectral (MA *et al.*, 2019).

Estudos recentes reforçam o potencial dos algoritmos de aprendizado de máquina para aplicações em sensoriamento remoto. Samat *et al.* (2018) verificaram elevado desempenho do *Extra Trees* na classificação de imagens de altíssima resolução espacial, destacando sua eficiência na discriminação de classes urbanas complexas. Patel e Suthar (2022) também observaram resultados superiores obtidos por algoritmos supervisionados em comparação com métodos convencionais de classificação, evidenciando sua capacidade de lidar com ambientes caracterizados por elevada heterogeneidade espacial. De forma semelhante, Park *et al.* (2022) demonstraram que algoritmos baseados em aprendizado de máquina apresentam ganhos expressivos de desempenho quando associados à utilização conjunta de atributos espectrais e topográficos.

Dessa forma, observa-se que o avanço das técnicas de aprendizado de máquina tem contribuído significativamente para o aprimoramento da classificação de imagens de sensoriamento remoto. A combinação entre algoritmos robustos e conjuntos de atributos capazes de representar diferentes características da superfície terrestre tem permitido a obtenção de produtos cartográficos mais precisos, consolidando essas abordagens como ferramentas fundamentais para o mapeamento da cobertura e uso da terra e da vegetação arbórea em ambientes urbanos.

3.3 Contribuição de Atributos Espectrais e Topográficos para a Classificação

A qualidade dos processos de classificação em sensoriamento remoto depende não apenas do algoritmo empregado, mas também da seleção dos atributos utilizados durante o treinamento dos modelos. Os atributos representam as características que descrevem cada elemento da imagem e constituem a base para a diferenciação entre as classes temáticas. Segundo Meneses, Almeida e Sano (2012), a escolha adequada dessas variáveis influencia diretamente a capacidade dos classificadores em representar a variabilidade da superfície terrestre e, consequentemente, a precisão dos produtos cartográficos obtidos. Da mesma forma, Ma *et al.* (2019) destacam que o desempenho dos algoritmos de aprendizado de máquina está fortemente relacionado à qualidade, diversidade e complementaridade das variáveis de entrada.

Os atributos espectrais constituem a principal fonte de informação utilizada na classificação de imagens de sensoriamento remoto. As bandas RGB registram a reflectância da superfície nos comprimentos de onda do vermelho (Red), verde (Green) e azul (Blue), permitindo diferenciar materiais e coberturas de acordo com suas respostas à radiação eletromagnética (MENESES; ALMEIDA; SANO, 2012). Entretanto, em imagens de altíssima resolução espacial, diferentes classes podem apresentar assinaturas espectrais semelhantes, especialmente em ambientes urbanos, nos quais materiais como concreto, solo exposto e determinadas coberturas apresentam respostas espectrais próximas. Além disso, objetos pertencentes à mesma classe podem apresentar elevada variabilidade interna devido à presença de sombras, diferentes condições de iluminação e características construtivas, dificultando a discriminação apenas por meio das bandas espectrais (BLASCHKE, 2010; MAXWELL; WARNER; FANG, 2018).

Uma alternativa para ampliar o potencial discriminatório das imagens consiste na utilização de transformações espectrais, como o sistema IHS (Intensidade, Matiz e Saturação).

Essa transformação separa a informação relacionada ao brilho da informação referente à cor, permitindo realçar diferenças pouco perceptíveis nas bandas RGB originais e favorecendo a identificação de diferentes padrões presentes na paisagem (MENESES; ALMEIDA; SANO, 2012). Dessa forma, a incorporação dos componentes IHS pode contribuir para aumentar a separabilidade entre classes que apresentam comportamento espectral semelhante, especialmente em áreas urbanizadas.

Embora os atributos espectrais desempenhem papel fundamental na classificação, estudos recentes demonstram que sua utilização isolada nem sempre é suficiente para representar a complexidade da superfície terrestre. Nesse contexto, atributos topográficos derivados de Modelos Digitais de Elevação têm sido amplamente incorporados aos processos de classificação por fornecerem informações relacionadas à geometria e à estrutura tridimensional da paisagem (PARK *et al.*, 2022).

Entre esses atributos, o Modelo Digital de Terreno (MDT) representa a superfície do terreno desconsiderando a presença de edificações, árvores e demais objetos, sendo amplamente utilizado em análises geomorfológicas e hidrológicas. O Modelo Digital de Superfície (MDS), por sua vez, representa a superfície considerando todos os elementos existentes sobre o terreno, como vegetação e construções. A diferença entre esses dois modelos origina o Modelo Digital de Superfície Normalizado (nDSM), atributo que representa a altura relativa dos objetos em relação ao terreno e constitui uma das variáveis mais relevantes para aplicações envolvendo classificação da cobertura e uso da terra em ambientes urbanos (PARK *et al.*, 2022; AYDIN; SEFERCIK, 2025).

Outro atributo amplamente empregado é a declividade, derivada dos Modelos Digitais de Elevação, que descreve a inclinação da superfície terrestre. Essa variável auxilia na diferenciação de áreas com distintas características geomorfológicas e pode contribuir para reduzir ambiguidades entre classes que apresentam assinaturas espectrais semelhantes, principalmente quando associada a atributos altimétricos e espectrais (MENESES; ALMEIDA; SANO, 2012).

Diversos estudos têm demonstrado que a integração entre atributos espectrais e topográficos produz resultados superiores aos obtidos pela utilização isolada desses conjuntos de dados. Park *et al.* (2022) verificaram que a incorporação do nDSM e de outros atributos derivados do relevo proporcionou ganhos significativos de acurácia na classificação de imagens de altíssima resolução espacial. Resultados semelhantes foram obtidos por Aydin e Sefercik (2025), que identificaram o nDSM como uma das variáveis mais relevantes para distinguir áreas vegetadas e edificadas em ambientes urbanos. Ben Miled *et al.* (2025)

também observaram que a combinação de informações espectrais e altimétricas aumenta a capacidade dos algoritmos de aprendizado de máquina em discriminar classes com elevada similaridade espectral, reduzindo erros de classificação.

Além de melhorar a separabilidade entre classes, a utilização conjunta de atributos espectrais e topográficos contribui para reduzir a influência de fatores como sombras, variações de iluminação e heterogeneidade interna dos alvos, problemas frequentemente observados em imagens de altíssima resolução espacial (MAXWELL; WARNER; FANG, 2018). Dessa forma, a integração dessas variáveis tem se consolidado como uma das principais estratégias para o aprimoramento dos processos de classificação supervisionada, possibilitando a geração de mapas de cobertura e uso da terra mais precisos e confiáveis.

Considerando essas evidências, observa-se que a utilização integrada de bandas espectrais, transformações radiométricas e atributos derivados de modelos digitais de elevação amplia significativamente o potencial dos algoritmos de aprendizado de máquina para o mapeamento temático. Essa abordagem permite explorar simultaneamente características relacionadas à composição espectral, à estrutura vertical e à morfologia da superfície, favorecendo a discriminação de classes complexas e contribuindo para o aprimoramento do mapeamento da cobertura e uso da terra e da vegetação arbórea em ambientes urbanos.

3.4 Imagens de Altíssima Resolução Espacial e Aplicações em Ambientes Urbanos

O avanço das tecnologias de aquisição de dados geoespaciais tem ampliado significativamente a disponibilidade de imagens de altíssima resolução espacial, permitindo representar a superfície terrestre com elevado nível de detalhamento. Esse avanço possibilitou a identificação de elementos urbanos de pequenas dimensões, como edificações, vias, árvores isoladas, áreas impermeabilizadas e corpos hídricos, favorecendo aplicações relacionadas ao planejamento urbano, monitoramento ambiental, cadastro territorial e gestão de recursos naturais (BLASCHKE, 2010; MENESES; ALMEIDA; SANO, 2012).

Em comparação às imagens de média resolução espacial, os produtos de altíssima resolução permitem representar com maior fidelidade a heterogeneidade das paisagens urbanas, possibilitando a diferenciação de elementos anteriormente agrupados em uma mesma classe temática. Essa característica favorece a elaboração de mapas de cobertura e uso da terra mais detalhados, além de ampliar as possibilidades de identificação da vegetação arbórea urbana, aspecto cada vez mais relevante para estudos voltados ao planejamento ambiental e à mitigação das ilhas de calor (ROY; BYRNE; PICKERING, 2012).

Diferentemente de imagens de satélite de média resolução espacial, como as provenientes das missões Landsat e Sentinel-2, que apresentam resoluções de *30 m* e *10 m*, respectivamente, as ortoimagens aerofotogramétricas de altíssima resolução espacial permitem a identificação de elementos urbanos de pequenas dimensões, como árvores isoladas, edificações, vias estreitas e áreas impermeabilizadas. Essa característica reduz a ocorrência de pixels mistos e aumenta a capacidade de discriminação entre diferentes classes de cobertura e uso da terra, favorecendo a obtenção de produtos cartográficos mais detalhados e precisos (MENESES; ALMEIDA; SANO, 2012; BLASCHKE, 2010; MAXWELL; WARNER; FANG, 2018).

Entretanto, o aumento da resolução espacial também impõe novos desafios aos processos de classificação. Em imagens de altíssima resolução, a elevada variabilidade interna das classes faz com que objetos pertencentes à mesma categoria apresentem respostas espectrais distintas, enquanto diferentes classes podem apresentar assinaturas semelhantes. Segundo Blaschke (2010), essa heterogeneidade reduz a eficiência de classificadores convencionais e exige abordagens capazes de integrar diferentes fontes de informação.

Nesse contexto, algoritmos de aprendizado de máquina têm se mostrado particularmente adequados para o processamento desse tipo de dado. Maxwell, Warner e Fang (2018) destacam que esses métodos apresentam maior capacidade de explorar relações complexas entre atributos espectrais, espaciais e topográficos, possibilitando ganhos significativos na precisão das classificações quando comparados a métodos estatísticos tradicionais.

Estudos recentes corroboram esse cenário. Patel e Suthar (2022) verificaram que a combinação de atributos derivados de imagens de alta resolução com algoritmos supervisionados proporcionou elevados índices de acurácia no mapeamento da cobertura e uso da terra em áreas urbanas. Resultados semelhantes foram obtidos por Samat *et al.* (2018), que demonstraram o elevado desempenho do algoritmo *Extra Trees* na classificação de imagens de altíssima resolução espacial. De maneira complementar, Pelletier, Valero e Inglada (2016) evidenciaram que algoritmos baseados em árvores de decisão apresentam elevada robustez para classificação de grandes conjuntos de dados de cobertura e uso da terra, reforçando seu potencial para aplicações em ambientes urbanos complexos.

Considerando a elevada heterogeneidade espacial presente na Região Metropolitana do Recife, caracterizada pela coexistência de áreas densamente urbanizadas, fragmentos vegetados, corpos hídricos e diferentes padrões de ocupação do solo, a utilização de imagens de altíssima resolução espacial associadas a algoritmos de aprendizado de máquina e atributos

topográficos apresenta elevado potencial para aprimorar a representação da paisagem e aumentar a precisão dos produtos cartográficos gerados (PARK *et al.*, 2022; AYDIN; SEFERCIK, 2025).

3.5 Projeto Pernambuco Tridimensional (PE3D)

O Projeto Pernambuco Tridimensional (PE3D) constitui uma importante iniciativa voltada à produção de dados geoespaciais de alta precisão para o estado de Pernambuco. Desenvolvido pelo Governo do Estado por meio da Secretaria de Recursos Hídricos e Saneamento, o projeto foi concebido para realizar levantamentos aerofotogramétricos e altimétricos de extensas áreas do território pernambucano, disponibilizando produtos cartográficos destinados ao apoio do planejamento urbano, da gestão ambiental, da infraestrutura, do monitoramento territorial e do desenvolvimento de pesquisas científicas (GOVERNO DE PERNAMBUCO, [s.d.]).

Entre os principais produtos disponibilizados destacam-se as ortofotocartas digitais de altíssima resolução espacial, os Modelos Digitais de Terreno (MDT), os Modelos Digitais de Superfície (MDS) e as nuvens de pontos obtidas por tecnologia LiDAR (*Light Detection and Ranging*). Esses produtos fornecem informações detalhadas sobre a superfície terrestre e sua estrutura tridimensional, permitindo a obtenção de atributos geomorfológicos e altimétricos que complementam os dados espectrais tradicionalmente utilizados em aplicações de sensoriamento remoto (MENESES; ALMEIDA; SANO, 2012).

As ortofotocartas produzidas pelo PE3D apresentam resolução espacial de *0,50 m*, possibilitando a identificação precisa de elementos da paisagem, como edificações, árvores isoladas, vias, corpos hídricos, áreas impermeabilizadas e diferentes tipos de cobertura vegetal. Já os Modelos Digitais de Terreno (MDT) e os Modelos Digitais de Superfície (MDS) possuem resolução espacial de *1 m*, fornecendo informações altimétricas compatíveis com aplicações que demandam elevada precisão na representação tridimensional da superfície terrestre. Esses produtos constituem importantes fontes de informação para análises geomorfológicas, ambientais e urbanas (GOVERNO DE PERNAMBUCO, [s.d.]).

Em comparação com imagens de satélite amplamente utilizadas em estudos de cobertura e uso da terra, como Landsat e Sentinel-2, cujas resoluções espaciais são de aproximadamente *30 m* e *10 m*, respectivamente, as ortofotocartas do PE3D permitem representar a superfície terrestre com nível de detalhamento significativamente superior. Essa característica reduz a ocorrência de pixels mistos, favorece a identificação de elementos

urbanos de pequenas dimensões, como árvores isoladas, vias estreitas e pequenas edificações, e contribui para a produção de mapas temáticos mais precisos (MENESES; ALMEIDA; SANO, 2012; BLASCHKE, 2010; MAXWELL; WARNER; FANG, 2018).

A literatura tem demonstrado que a integração entre informações espectrais e topográficas representa uma das principais estratégias para aumentar a precisão da classificação da cobertura e uso da terra. Segundo Park *et al.* (2022), atributos derivados de modelos digitais de elevação, especialmente o nDSM, contribuem significativamente para a diferenciação entre edificações, vegetação e outras classes urbanas. Resultados semelhantes foram observados por Aydin e Sefercik (2025), que identificaram ganhos expressivos de desempenho decorrentes da utilização conjunta de atributos espectrais e altimétricos em algoritmos de aprendizado de máquina.

Além da elevada qualidade dos produtos cartográficos, outro diferencial do PE3D consiste na disponibilidade integrada de informações planimétricas e altimétricas obtidas para uma mesma área, permitindo explorar simultaneamente características espectrais e estruturais da paisagem. Essa integração amplia as possibilidades de aplicação dos dados em estudos envolvendo classificação supervisionada, modelagem ambiental, análise da vegetação urbana e monitoramento territorial.

Nesse contexto, os produtos disponibilizados pelo PE3D constituem uma base de dados especialmente adequada para pesquisas voltadas ao mapeamento da cobertura e uso da terra. A combinação de ortofotocartas de altíssima resolução espacial com atributos derivados dos modelos digitais de elevação fornece um conjunto de variáveis capaz de potencializar o desempenho de algoritmos de aprendizado de máquina, favorecendo a produção de mapas temáticos mais precisos e confiáveis. Tal potencial é corroborado por estudos recentes que demonstram ganhos significativos de acurácia quando informações topográficas são incorporadas aos processos de classificação supervisionada (PARK *et al.*, 2022; AYDIN; SEFERCIK, 2025; BEN MILED *et al.*, 2025).

4. MATERIAS E MÉTODOS


4.1 Área de Estudo

A área de estudo localiza-se entre os municípios de Recife, Camaragibe, Olinda, Paulista e São Lourenço da Mata no estado de Pernambuco (Figura 1). A escolha dessa região deve-se ao expressivo contraste entre áreas densamente urbanizadas e extensas áreas de

preservação ambiental, destacando-se a presença do Parque Estadual de Dois Irmãos e de outras reservas ecológicas inseridas em um contexto de intensa ocupação urbana.

Além disso, a área apresenta características geomorfológicas relevantes, com ocorrência de relevo acidentado e numerosas encostas. A região também possui diversos corpos hídricos distribuídos ao longo de sua extensão, os quais desempenham importante papel na configuração da paisagem e nas condições ambientais locais.

Figura 1 – Mapa de localização da área de estudo



Fonte: Autor, 2026.

4.2 Materiais

Os dados utilizados neste trabalho foram obtidos por meio da plataforma Pernambuco Tridimensional (PE3D).


Para a área de estudo, foram selecionadas e baixadas nove quadriculas que abrangem integralmente a região analisada. Dentre os produtos disponibilizados pelo PE3D, foram utilizadas as ortofotografias RGB com resolução espacial de $0,50\text{ m}$, bem como os Modelos Digitais de Terreno (MDT) e os Modelos Digitais de Superfície (MDS), ambos com resolução espacial de 1 m . As ortofotografias foram empregadas na extração dos atributos espectrais (RGB e IHS), enquanto os modelos digitais serviram de base para a geração dos atributos topográficos utilizados nas classificações supervisionadas. A elevada resolução espacial desses produtos possibilita a identificação detalhada de elementos da paisagem urbana, como edificações, vias, corpos hídricos e diferentes tipos de vegetação, fornecendo informações adequadas para o mapeamento da cobertura e uso da terra.

4.3 Métodos

4.3.1 Procedimentos metodológicos

Os procedimentos metodológicos adotados neste trabalho foram divididos em quatro etapas principais: preparação dos dados de entrada, geração de atributos derivados, coleta das amostras para treinamento e validação, e execução das classificações supervisionadas conforme Figura 2.

Figura 2 – Fluxograma Metodológico



Fonte: Autor, 2026.

4.3.2 Preparação dos dados e normalização do terreno

Inicialmente, foram preparados os produtos derivados do relevo a partir dos dados altimétricos disponibilizados pelo Programa Pernambuco Tridimensional (PE3D) (GOVERNO DE PERNAMBUCO, [s.d.]). Como primeira etapa, foi gerado o Modelo Digital de Superfície Normalizado (nDSM) utilizando a ferramenta Calculadora Raster do software

QGIS, a partir da diferença entre o Modelo Digital de Superfície (MDS) e o Modelo Digital do Terreno (MDT).

Posteriormente, foi gerado um raster de declividade em porcentagem a partir do MDS, visando incorporar informações relacionadas à heterogeneidade da superfície. Esse atributo auxilia na diferenciação entre classes que apresentam padrões estruturais distintos e tem sido amplamente empregado em estudos de classificação da cobertura e uso da terra (PARK *et al.*, 2022).

Após a obtenção desses produtos, realizou-se o empilhamento das bandas correspondentes ao MDT, nDSM e declividade, formando um conjunto de dados representativo das características topográficas da área de estudo. Essa etapa permitiu a integração de informações relacionadas à elevação, altura dos objetos e variação do relevo, compondo um conjunto de atributos utilizado no processo de classificação supervisionada.

4.3.3 Transformação IHS das imagens RGB

Além das informações topográficas, foram utilizadas ortoimagens RGB com resolução espacial de $0,50\text{ m}$, compostas pelas bandas espectrais *Red* (R), *Green* (G) e *Blue* (B). Essa resolução espacial significa que cada pixel da imagem representa uma área de aproximadamente $0,50 \times 0,50\text{ m}$ na superfície terrestre, permitindo a identificação de elementos urbanos de pequenas dimensões, como árvores isoladas, vias, edificações e corpos hídricos.

Com o objetivo de explorar diferentes características espectrais, foi realizada a transformação do espaço de cores RGB para o sistema IHS (Intensidade, Matiz e Saturação), utilizando ferramentas do módulo GRASS GIS integradas ao QGIS.

A componente Intensidade representa o brilho total da imagem, a Matiz descreve a tonalidade predominante associada às diferentes coberturas terrestres, enquanto a Saturação indica o grau de pureza das cores. A utilização dessas variáveis buscou fornecer informações complementares para melhorar a discriminação entre as classes de interesse, especialmente quando combinadas aos atributos topográficos derivados do MDT, MDS e nDSM.

4.3.4 Coleta das amostras de treinamento

A etapa de amostragem consistiu na coleta manual de amostras representativas das classes temáticas presentes na área de estudo. Para a coleta das amostras, optou-se pela

utilização de pontos em vez de polígonos, uma vez que essa abordagem proporcionou maior rapidez no processamento das classificações e menor demanda de memória computacional durante a execução dos algoritmos no software QGIS.

Adotou-se como critério a obtenção de aproximadamente 800 amostras para cada classe, as quais foram coletadas ponto a ponto, buscando garantir uma representação equilibrada entre as categorias analisadas e reduzir possíveis vieses decorrentes do desbalanceamento amostral. A utilização de quantidades semelhantes de amostras por classe contribui para um treinamento mais adequado dos algoritmos de classificação supervisionada, favorecendo a identificação dos padrões espectrais e topográficos característicos de cada categoria e aumentando a confiabilidade dos resultados obtidos.

A exceção ocorreu para a classe Corpos d'água, que apresentou quantidade insuficiente de feições na área de estudo para atingir o número estabelecido de amostras. Nesse caso, foram coletadas todas as amostras disponíveis, de modo a representar adequadamente essa categoria.

As classes consideradas nesta etapa foram: Edificações, Sombras, Vegetação de Grande Porte, Vegetação de Pequeno Porte, Solo Exposto, Corpos d'água e Vias.

Além da classificação multiclasse da cobertura e uso da terra, foi realizado um experimento específico para o mapeamento da vegetação arbórea. Para essa etapa, as amostras foram reorganizadas em duas classes: Vegetação de Grande Porte e Não Vegetação de Grande Porte, sendo esta última composta por todas as demais classes presentes na área de estudo. Essa abordagem teve como objetivo avaliar o potencial dos algoritmos na identificação da cobertura arbórea urbana.

Para essa classificação binária, foram coletadas aproximadamente 5.000 amostras para cada classe, visando ampliar a representatividade do conjunto de treinamento e fornecer uma base amostral mais robusta para o treinamento e a avaliação dos classificadores na identificação da vegetação arbórea.

4.3.5 Classificação supervisionada das imagens

As classificações supervisionadas foram realizadas utilizando o plugin *Dzetsaka*, disponível no software QGIS. A escolha dessa ferramenta deve-se à sua integração com o ambiente SIG, à disponibilidade de diferentes algoritmos de aprendizado de máquina e aos recursos para treinamento, validação e avaliação automática dos classificadores, tornando-a

uma ferramenta amplamente utilizada em aplicações de classificação supervisionada de imagens de sensoriamento remoto.

Foram avaliados os algoritmos *Random Forest* (RF), *Extra Trees* (ET) e *Gaussian Mixture Model* (GMM), visando comparar o desempenho de diferentes abordagens de classificação supervisionada aplicadas a imagens de altíssima resolução espacial. A escolha desses algoritmos baseou-se em sua ampla utilização em estudos de sensoriamento remoto e na capacidade de lidar com grandes volumes de dados e relações complexas entre atributos espectrais e topográficos. O *Random Forest* destaca-se por sua robustez frente a ruídos e ao sobreajuste (*overfitting*), enquanto o *Extra Trees* incorpora maior aleatoriedade na construção das árvores de decisão, favorecendo a capacidade de generalização dos modelos (BREIMAN, 2001; GEURTS; ERNST; WEHENKEL, 2006). Já o *Gaussian Mixture Model* baseia-se em uma abordagem probabilística, na qual a distribuição dos dados é representada por uma combinação de distribuições gaussianas, sendo amplamente empregado em tarefas de classificação e reconhecimento de padrões (BISHOP, 2006). Segundo Maxwell, Warner e Fang (2018), algoritmos de aprendizado de máquina apresentam desempenho superior aos métodos tradicionais em diversas aplicações de sensoriamento remoto, especialmente quando empregados em imagens de alta resolução espacial e em conjuntos de dados compostos por múltiplos atributos.

No processo de treinamento e validação, o plugin *Dzetsaka* realizou automaticamente a divisão das amostras em conjuntos independentes. Essa estratégia é amplamente empregada em aprendizado de máquina, pois permite treinar os modelos com parte dos dados e avaliar seu desempenho utilizando amostras não empregadas no treinamento, reduzindo o risco de sobreajuste e fornecendo uma estimativa mais confiável da capacidade de generalização dos classificadores (MAXWELL; WARNER; FANG, 2018; BELGIU; DRĂGUT, 2016). Os percentuais de treinamento e validação não foram definidos pelo pesquisador, sendo estabelecidos automaticamente pelo plugin *Dzetsaka* durante a execução de cada algoritmo. Dessa forma, foram utilizados 75% das amostras para treinamento e 25% para validação nos algoritmos *Extra Trees* e *Gaussian Mixture Model* (GMM), enquanto, para o algoritmo *Random Forest*, foram utilizados 70% das amostras para treinamento e 30% para validação.

Para cada algoritmo, foram executados quatro cenários distintos de classificação para o mapeamento da cobertura e uso da terra:

- Classificação utilizando exclusivamente as bandas espectrais RGB;
- Classificação utilizando os atributos topográficos resultantes da normalização do terreno (MDT, nDSM e declividade);

- Classificação utilizando apenas as componentes IHS (Intensidade, Matiz e Saturação);
- Classificação utilizando o conjunto completo de variáveis, composto pelas bandas RGB, componentes IHS, MDT, nDSM e declividade.

Além da classificação multiclasse da cobertura e uso da terra, foi realizado um experimento específico para o mapeamento da vegetação arbórea. Nessa etapa, as amostras binarizadas foram classificadas em Vegetação de Grande Porte e Não Vegetação de Grande Porte, empregando os mesmos algoritmos avaliados neste estudo (*Gaussian Mixture Model*, *Random Forest* e *Extra Trees*).

Para o mapeamento da vegetação arbórea, foram considerados três cenários distintos de classificação: (i) utilização exclusiva das bandas espectrais RGB; (ii) utilização dos atributos topográficos (MDT, nDSM e declividade); e (iii) utilização conjunta dos atributos espectrais RGB e dos atributos topográficos.

O desempenho dos algoritmos em todos os experimentos foi avaliado por meio das matrizes de confusão geradas pelo plugin Dzetsaka. Como principal métrica de desempenho, foi utilizada a precisão global (*Overall Accuracy*), calculada pela razão entre o número de amostras corretamente classificadas e o número total de amostras avaliadas (MANGABEIRA; AZEVEDO; LAMPARELLI, 2003). Além da precisão global, a análise das matrizes de confusão permitiu identificar a distribuição dos erros entre as classes temáticas, possibilitando comparar o desempenho dos diferentes algoritmos e das combinações de atributos espectrais e topográficos empregadas neste estudo.

5. RESULTADOS E DISCUSSÃO

5.1 Classificação utilizando as bandas RGB


Nesta seção são apresentados os resultados obtidos a partir da classificação supervisionada utilizando exclusivamente as bandas espectrais RGB. O desempenho dos algoritmos *Gaussian Mixture Model* (GMM), *Random Forest* (RF) e *Extra Trees* (ET) foi analisado com base nos mapas temáticos gerados e nas matrizes de confusão, permitindo avaliar a capacidade de discriminação das classes de cobertura e uso da terra empregando apenas informações espectrais.

5.1.1 RGB por meio do algoritmo GMM

A classificação supervisionada realizada por meio do Modelo de Mistura Gaussiana (*Gaussian Mixture Model* – GMM) apresentou precisão global de 69,5% (Figura 3). A análise da matriz de confusão (Figura 4) indicou que a classe Sombra apresentou o maior número de acertos, com 164 amostras corretamente classificadas. Em contrapartida, a classe Corpos d'água apresentou o menor desempenho entre as classes avaliadas.


A análise visual do mapa temático revelou que, apesar da boa identificação da classe Sombra, ocorreu elevada confusão espectral entre as classes Sombra e Corpos d'água, resultando na classificação incorreta de diversos corpos hídricos como áreas sombreadas. Esse comportamento pode estar associado à semelhança das respostas espectrais dessas classes nas bandas RGB, especialmente em regiões de baixa reflectância (MENESES; ALMEIDA; SANO, 2012). Além disso, observaram-se confusões entre as classes Vias e Solo Exposto, indicando limitações do uso exclusivo das informações espectrais para a diferenciação de alvos com características semelhantes.

Figura 3 – Mapa Temático: RGB por meio do algoritmo GMM



Fonte: Autor, 2026.

Figura 4 – Matriz de Confusão: RGB por meio do algoritmo GMM



Legenda		
1 – Edificações;	5 – Vegetação de Grande Porte;	8 – Sombra.
2 – Solo Exposto;	6 - Vegetação de Pequeno Porte;	
3 – Vias;	7 – Corpos d'água;	

Fonte: Autor, 2026.

5.1.2 RGB por meio do algoritmo RF


A classificação supervisionada utilizando o algoritmo Random Forest alcançou precisão global de 70,8% (Figura 5). De acordo com a matriz de confusão (Figura 6), a classe Solo Exposto apresentou o maior número de amostras corretamente classificadas, enquanto a classe Corpos d'água permaneceu com o menor desempenho entre as classes avaliadas.

A análise visual do mapa temático indicou que o *Random Forest* promoveu melhorias na discriminação das classes em relação ao *Gaussian Mixture Model* (GMM), resultando em uma representação espacial mais consistente. Entretanto, ainda foi observada elevada confusão entre as classes Corpos d'água e Sombra, ocasionando um aspecto mais fragmentado em determinadas regiões do mapa. Essa limitação pode ser atribuída à elevada similaridade espectral entre essas classes nas bandas RGB, especialmente em áreas de baixa reflectância,

dificultando sua separação quando apenas atributos espectrais são empregados (MENESES; ALMEIDA; SANO, 2012).


Embora o Random Forest seja reconhecido por sua elevada capacidade de modelar relações não lineares e por sua robustez frente à variabilidade dos dados (BREIMAN, 2001; BELGIU; DRĂGUT, 2016), seu desempenho depende diretamente da qualidade e da capacidade discriminatória dos atributos utilizados. Dessa forma, os resultados obtidos sugerem que a utilização exclusiva das bandas RGB limita o potencial do algoritmo para distinguir classes com assinaturas espectrais semelhantes, indicando que a incorporação de atributos topográficos, como o nDSM e a declividade, pode contribuir para reduzir essas ambiguidades e aumentar a precisão da classificação, conforme observado por Park *et al.* (2022) e Aydin e Sefercik (2025).

Figura 5 – Mapa Temático: RGB por meio do algoritmo RF



Fonte: Autor, 2026.

Figura 6 – Matriz de Confusão: RGB por meio do algoritmo RF



Legenda		
1 – Edificações;	5 – Vegetação de Grande Porte;	8 – Sombra.
2 – Solo Exposto;	6 - Vegetação de Pequeno Porte;	
3 – Vias;	7 – Corpos d’água;	

Fonte: Autor, 2026.

5.1.3 RGB por meio do algoritmo ET


O algoritmo *Extra Trees* apresentou a melhor precisão entre os métodos avaliados para as bandas RGB, atingindo 71,5% (Figura 7). A matriz de confusão (Figura 8) indicou que a classe Sombra obteve o maior número de amostras corretamente classificadas, enquanto a classe Corpos d’água novamente apresentou o menor desempenho.

A inspeção visual do mapa temático mostrou que, apesar do melhor desempenho geral do algoritmo, persistiram dificuldades na discriminação entre algumas classes de vegetação. Observou-se elevada confusão entre Vegetação de Grande Porte, Vegetação de Pequeno Porte e Sombra, indicando que a utilização exclusiva das bandas RGB não forneceu informações suficientes para diferenciar adequadamente classes com características espectrais semelhantes.

O desempenho superior do *Extra Trees* em relação aos demais algoritmos avaliados pode estar relacionado ao maior grau de aleatoriedade empregado na construção das árvores de decisão, característica que tende a reduzir a variância do modelo e favorecer sua capacidade de generalização (GEURTS; ERNST; WEHENKEL, 2006). Estudos realizados por Samat *et al.* (2018) também evidenciaram o elevado potencial desse algoritmo na classificação de imagens de altíssima resolução espacial, especialmente em ambientes urbanos complexos.


Entretanto, os resultados obtidos indicam que, mesmo apresentando melhor desempenho entre os classificadores avaliados para as bandas RGB, o *Extra Trees* permaneceu limitado pela disponibilidade exclusiva de informações espectrais. A dificuldade em distinguir diferentes tipos de vegetação e áreas sombreadas reforça a importância da incorporação de atributos topográficos, como o nDSM e a declividade, capazes de representar diferenças estruturais entre os alvos e reduzir ambiguidades na classificação, conforme observado por Park *et al.* (2022) e Aydin e Sefercik (2025).

Figura 7 – Mapa Temático: RGB por meio do algoritmo ET



Fonte: Autor, 2026.

Figura 8 – Matriz de Confusão: RGB por meio do algoritmo ET



Legenda		
1 – Edificações;	5 – Vegetação de Grande Porte;	8 – Sombra.
2 – Solo Exposto;	6 - Vegetação de Pequeno Porte;	
3 – Vias;	7 – Corpos d'água;	

Fonte: Autor, 2026.

5.1.4 Comparação entre GMM, RF e ET utilizando o RGB

A comparação entre os três algoritmos aplicados às bandas RGB demonstrou diferenças no desempenho da classificação supervisionada. O algoritmo *Extra Trees* (ET) apresentou a maior precisão (71,5%), seguido pelo *Random Forest* (RF), com 70,8%, e pelo *Gaussian Mixture Model* (GMM), com 69,5%.

De maneira geral, os três métodos apresentaram dificuldades na identificação da classe Corpos d'água, que registrou os menores índices de acerto nas matrizes de confusão. A principal fonte de erro observada foi a confusão entre as classes Corpos d'água e Sombra, evidenciada tanto nas matrizes de confusão quanto na análise visual dos mapas classificados. Essa limitação pode ser atribuída à similaridade espectral dessas feições nas bandas RGB,

uma vez que ambas apresentam baixos valores de reflectância, dificultando sua distinção quando apenas informações espectrais são utilizadas (MENESES; ALMEIDA; SANO, 2012).

Em relação às demais classes, o GMM apresentou melhor desempenho na identificação da classe Sombra, enquanto o RF obteve melhores resultados para a classe Solo Exposto. O ET, por sua vez, destacou-se por apresentar a maior precisão global, indicando maior capacidade de generalização durante o processo de classificação. Esse comportamento está de acordo com Geurts, Ernst e Wehenkel (2006), que destacam a eficiência do *Extra Trees* em reduzir a variância do modelo por meio de uma maior aleatoriedade na construção das árvores de decisão. Resultados semelhantes também foram observados por Samat *et al.* (2018), que verificaram o bom desempenho do algoritmo na classificação de imagens de alta resolução espacial.

Apesar do melhor desempenho do *ET*, foram observadas confusões significativas entre as classes Vegetação de Grande Porte, Vegetação de Pequeno Porte e Sombra, sugerindo que a utilização exclusiva das bandas RGB não é suficiente para representar adequadamente as diferenças estruturais entre esses alvos. Nesse contexto, a incorporação de atributos complementares, como o nDSM e variáveis topográficas, tende a aumentar a capacidade de discriminação entre classes com assinaturas espectrais semelhantes, conforme demonstrado por Park *et al.* (2022) e Aydin e Sefercik (2025).

5.2 IHS

Com o objetivo de avaliar a influência da transformação IHS na classificação da cobertura e uso da terra, as bandas RGB foram convertidas para os componentes Intensidade (*Intensity*), Matiz (*Hue*) e Saturação (*Saturation*). Em seguida, esses atributos foram utilizados como dados de entrada para os algoritmos *Gaussian Mixture Model* (GMM), *Random Forest* (RF) e *Extra Trees* (ET), permitindo comparar o desempenho dos classificadores em relação ao uso exclusivo das bandas RGB. A utilização da transformação IHS buscou explorar informações relacionadas à intensidade luminosa, à tonalidade e à saturação das cores, que podem favorecer a discriminação entre determinadas classes de cobertura e uso da terra.

5.2.1 IHS por meio do algoritmo GMM


O *Gaussian Mixture Model (GMM)* alcançou uma precisão de 66,0%, sendo classificado como um desempenho médio. A análise da matriz de confusão (Figura 10) demonstrou que a classe Sombra apresentou o maior número de amostras corretamente classificadas. Em contrapartida, a classe Corpos d'água não apresentou nenhuma amostra classificada corretamente pelo modelo.

A análise visual do mapa temático gerado pela classificação supervisionada (Figura 9) evidenciou elevada confusão entre as classes Corpos d'água e Sombra, sendo observada a classificação incorreta de grande parte dos corpos hídricos como áreas sombreadas. Além disso, verificou-se considerável sobreposição entre as classes Vegetação de Grande Porte, Vegetação de Pequeno Porte e Sombra, indicando limitações do *GMM* na discriminação dessas classes utilizando os atributos derivados da transformação IHS.

Esse desempenho pode estar relacionado às premissas estatísticas do *GMM*, que modela cada classe por meio de distribuições gaussianas. Quando diferentes classes apresentam elevada sobreposição nas características espectrais, a capacidade de separação do algoritmo tende a ser reduzida (BISHOP, 2006). No presente estudo, a transformação IHS não foi suficiente para eliminar a similaridade entre algumas classes, especialmente aquelas associadas a áreas sombreadas e corpos d'água.


Os resultados obtidos reforçam que, embora a transformação IHS possa favorecer a interpretação visual das imagens, sua utilização isolada não garante maior capacidade de discriminação entre alvos com assinaturas espectrais semelhantes. Dessa forma, a incorporação de atributos complementares, como variáveis topográficas ou informações estruturais, pode contribuir para melhorar o desempenho da classificação, conforme observado por Park *et al.* (2022) e Aydin e Sefercik (2025).

Figura 10 – Mapa Temático: IHS por meio do algoritmo GMM



Fonte: Autor, 2026.

Figura 11 – Matriz de Confusão: IHS por meio do algoritmo GMM



Legenda		
1 – Edificações;	5 – Vegetação de Grande Porte;	8 – Sombra.
2 – Solo Exposto;	6 - Vegetação de Pequeno Porte;	
3 – Vias;	7 – Corpos d'água;	

Fonte: Autor, 2026.

5.2.2 IHS por meio do algoritmo RF


A classificação supervisionada realizada com o algoritmo *Random Forest* (RF) apresentou uma precisão global de 71,6% (Figura 11). A partir da análise da imagem classificada (Figura 11) e da matriz de confusão correspondente (Figura 12), foi possível observar uma melhoria na identificação da classe Corpos d'água quando comparada ao modelo *Gaussian Mixture Model* (GMM).

Entretanto, áreas com elevada presença de vegetação associada a regiões sombreadas apresentaram significativa confusão entre as classes Sombra, Vegetação de Grande Porte e Corpos d'água, resultando em um aspecto mais fragmentado no mapa temático. A matriz de confusão indicou que a classe Sombra apresentou o maior número de amostras corretamente classificadas, enquanto a classe Vegetação de Grande Porte apresentou elevada confusão com

as classes Vegetação de Pequeno Porte e Sombra. Também foi observada confusão entre as classes Vias e Solo Exposto, evidenciando a similaridade espectral entre essas feições.


O desempenho obtido demonstra a capacidade do *Random Forest* em modelar relações complexas entre os atributos utilizados, característica amplamente descrita por Breiman (2001) e Belgiu e Drăguț (2016). No entanto, os resultados indicam que a utilização apenas das componentes derivadas da transformação IHS ainda não foi suficiente para eliminar a sobreposição espectral entre determinadas classes.

Figura 11 – Mapa Temático: IHS por meio do algoritmo RF



Fonte: Autor, 2026.

Figura 12 – Matriz de Confusão: IHS por meio do algoritmo RF



Legenda		
1 – Edificações;	5 – Vegetação de Grande Porte;	8 – Sombra.
2 – Solo Exposto;	6 – Vegetação de Pequeno Porte;	
3 – Vias;	7 – Corpos d'água;	

Fonte: Autor, 2026.

5.2.3 IHS por meio do algoritmo ET


O algoritmo *Extra Trees* (ET) alcançou uma precisão de 71,3%. A avaliação visual do mapa temático gerado (Figura 13) também demonstrou uma melhoria na classificação da classe Corpos d'água em relação ao GMM. No entanto, persistiram confusões significativas entre Corpos d'água e Sombra, principalmente em regiões com maior concentração de vegetação e áreas sombreadas, ocasionando um aspecto mais fragmentado na imagem classificada.

Além disso, observou-se elevada confusão entre as classes Solo Exposto, Edificações e Vias, resultando na classificação incorreta de pixels pertencentes a edificações como Solo Exposto. A análise da matriz de confusão (Figura 14) mostrou que a classe Sombra apresentou o maior número de amostras classificadas corretamente. Em contrapartida, a classe


Vegetação de Grande Porte apresentou elevada confusão com as classes Sombra e Vegetação de Pequeno Porte.

Apesar do desempenho semelhante ao obtido pelo *Random Forest*, o *Extra Trees* apresentou limitações na separação de classes com comportamento espectral semelhante. Embora esse algoritmo seja reconhecido pela elevada capacidade de generalização decorrente da maior aleatoriedade na construção das árvores de decisão (GEURTS; ERNST; WEHENKEL, 2006), a qualidade da classificação permanece diretamente relacionada ao poder discriminatório dos atributos utilizados. Resultados semelhantes foram relatados por Samat *et al.* (2018), que destacam o bom desempenho do *Extra Trees* em imagens de alta resolução, especialmente quando combinado com atributos espectrais e espaciais complementares. Dessa forma, a incorporação de informações topográficas, como o *nDSM* e a declividade, pode favorecer a distinção entre classes urbanas e vegetação, reduzindo as confusões observadas neste estudo (PARK *et al.*, 2022; AYDIN; SEFERCIK, 2025).

Figura 13 – Mapa Temático: IHS por meio do algoritmo ET



Fonte: Autor, 2026.

Figura 14 – Matriz de Confusão: IHS por meio do algoritmo ET

Fonte: Autor, 2026.

5.2.4 Comparação entre GMM, RF e ET utilizando o empilhamento IHS

A comparação entre os algoritmos *Gaussian Mixture Model* (GMM), *Random Forest* (RF) e *Extra Trees* (ET) aplicados aos atributos derivados da transformação IHS revelou diferenças no desempenho da classificação supervisionada. O algoritmo *Random Forest* apresentou a maior precisão entre os métodos avaliados, atingindo 71,6%, seguido pelo *Extra Trees*, com 71,3%, e pelo *Gaussian Mixture Model*, com 66,0%.

Os resultados demonstraram que tanto o RF quanto o ET apresentaram desempenhos bastante semelhantes, diferindo em apenas 0,3 ponto percentual. Ambos os algoritmos melhoraram a identificação da classe Corpos d'água em relação ao GMM, indicando maior capacidade de discriminação dos atributos derivados da transformação IHS. Em contraste, o GMM apresentou o menor desempenho geral, não conseguindo classificar corretamente nenhuma amostra pertencente à classe Corpos d'água, que foi predominantemente confundida

com a classe Sombra. Esse comportamento pode ser explicado pelas limitações do *Gaussian Mixture Model* na separação de classes com elevada sobreposição espectral, conforme discutido por Bishop (2006).

Uma característica comum observada nos três algoritmos foi a elevada taxa de acerto para a classe Sombra, que apresentou o maior número de amostras corretamente classificadas nas matrizes de confusão. Contudo, essa classe também esteve diretamente associada aos principais erros de classificação, especialmente devido à sua confusão com Corpos d'água e com as classes de vegetação. Esse resultado evidencia que a transformação IHS, embora forneça informações relacionadas à intensidade, matiz e saturação, não foi suficiente para eliminar a similaridade entre essas classes.

Além disso, tanto o RF quanto o ET apresentaram dificuldades na separação entre Vegetação de Grande Porte e Vegetação de Pequeno Porte, frequentemente associadas à classe Sombra. Esses resultados indicam que a utilização exclusiva dos atributos derivados da transformação IHS ainda apresenta limitações para representar diferenças estruturais entre os alvos, reforçando a necessidade da incorporação de atributos complementares, como o nDSM e variáveis topográficas, conforme observado por Park *et al.* (2022) e Aydin e Sefercik (2025).

De modo geral, os resultados demonstram que os algoritmos baseados em árvores de decisão, especialmente o *Random Forest*, apresentaram melhor desempenho quando aplicados aos atributos derivados da transformação IHS. Esse comportamento está de acordo com Breiman (2001) e Belgiu e Drăguț (2016), que destacam a elevada capacidade do *Random Forest* em modelar relações não lineares e lidar com dados complexos em aplicações de sensoriamento remoto.

5.3 Classificação do terreno

Para a classificação utilizando atributos derivados do terreno, a classe Sombra foi excluída do conjunto de amostras, uma vez que essa classe está diretamente relacionada às condições de iluminação e ao ângulo de incidência da radiação solar durante a aquisição da imagem, não representando uma classe temática de cobertura e uso da terra. Além disso, por não possuir características altimétricas próprias, sua inclusão poderia introduzir ambiguidades na classificação baseada em atributos topográficos. Dessa forma, buscou-se avaliar exclusivamente a contribuição das variáveis derivadas do terreno na discriminação das classes

de interesse, permitindo analisar de forma mais consistente o potencial dessas informações na separação dos diferentes alvos.

5.3.1 MDT, nDSM e Declividade por meio do algoritmo GMM


O *Gaussian Mixture Model* (GMM) alcançou uma precisão global de 49,3%. A partir da análise do mapa temático gerado pela classificação supervisionada (Figura 15), foi possível observar que áreas com elevada concentração de Vegetação de Grande Porte apresentaram resultados satisfatórios, indicando que o modelo foi capaz de identificar adequadamente feições com maior expressão altimétrica.

Entretanto, verificou-se elevada confusão entre as classes Solo Exposto, Corpos d'água e Vegetação de Pequeno Porte com a classe Vias, resultando em uma generalização excessiva dessa categoria no mapa temático.

A análise da matriz de confusão (Figura 16) demonstrou que a classe Vias apresentou o maior número de amostras corretamente classificadas. Contudo, ao comparar esses resultados com a distribuição espacial observada no mapa classificado, verificou-se que parte desse desempenho pode estar associada à superestimação da classe. Além disso, as classes Edificação, Solo Exposto e Vegetação de Pequeno Porte apresentaram apenas oito amostras corretamente classificadas cada, evidenciando elevada confusão com a classe Vias. A classe Corpos d'água apresentou o pior desempenho, registrando apenas uma amostra corretamente classificada e elevada confusão com a classe Vias.


O baixo desempenho do GMM pode estar relacionado às premissas estatísticas do algoritmo, que assume que as amostras de cada classe podem ser representadas por distribuições gaussianas. Quando diferentes classes apresentam valores altimétricos semelhantes ou elevada sobreposição nas variáveis derivadas do terreno, essa abordagem tende a reduzir a capacidade de discriminação entre os alvos (BISHOP, 2006). Os resultados obtidos indicam que, embora os atributos topográficos tenham contribuído para a identificação de feições com maior porte, como a Vegetação de Grande Porte, sua utilização isolada não foi suficiente para distinguir adequadamente classes com características estruturais semelhantes, evidenciando a necessidade de integrar informações espectrais e topográficas para melhorar o desempenho da classificação, conforme discutido por Aydin e Sefercik (2025).

Figura 15 – Mapa Temático: MDT, nDSM e Declividade por meio do algoritmo GMM



Fonte: Autor, 2026.

Figura 16 – Matriz de Confusão: MDT, nDSM e Declividade por meio do algoritmo GMM



Fonte: Autor, 2026.

5.3.2 MDT, nDSM e Declividade por meio do algoritmo RF

O algoritmo *Random Forest* (RF) apresentou uma precisão global de 56,1%. A partir da análise do mapa temático gerado (Figura 17), foi possível observar uma melhoria na classificação da classe Corpos d'água em relação ao modelo *Gaussian Mixture Model* (GMM). Também foi verificada uma boa representação da classe Vegetação de Grande Porte, principalmente em áreas com elevada concentração de cobertura vegetal. Além disso, observou-se uma melhora na identificação das Edificações.

Entretanto, foi identificada elevada confusão entre as classes Vias e Corpos d'água, resultando na classificação incorreta de diversas vias como corpos hídricos.


A análise da matriz de confusão (Figura 18) demonstrou que a classe Edificação apresentou o maior número de amostras corretamente classificadas. Em contrapartida, as classes Solo Exposto e Vegetação de Pequeno Porte apresentaram os menores índices de

acerto, indicando dificuldades do algoritmo na discriminação dessas classes utilizando exclusivamente atributos derivados do terreno.

Embora o *Random Forest* seja amplamente reconhecido por sua capacidade de modelar relações não lineares e lidar com conjuntos de dados complexos (BREIMAN, 2001; BELGIU; DRĂGUT, 2016), os resultados obtidos indicam que os atributos topográficos empregados não forneceram informações suficientes para distinguir algumas classes que apresentam comportamento altimétrico semelhante. A melhoria observada na identificação de Edificações e Vegetação de Grande Porte demonstra que variáveis como o MDT, o nDSM e a declividade possuem potencial para representar diferenças estruturais entre os alvos. No entanto, a elevada confusão entre Vias, Corpos d'água, Solo Exposto e Vegetação de Pequeno Porte evidencia que a utilização isolada dessas variáveis limita a capacidade discriminatória do algoritmo.


Esses resultados reforçam a importância da integração entre atributos espectrais e topográficos, uma vez que a combinação dessas informações tende a aumentar a separabilidade entre classes e a reduzir ambiguidades na classificação, conforme demonstrado por Park *et al.* (2022) e Aydin e Sefercik (2025).

Figura 17 – Mapa Temático: MDT, nDSM e Declividade por meio do algoritmo RF



Fonte: Autor, 2026.

Figura 18 – Matriz de Confusão: MDT, nDSM e Declividade por meio do algoritmo RF



Fonte: Autor, 2026.

5.3.3 MDT, nDSM e Declividade por meio do algoritmo ET

O algoritmo *Extra Trees* (ET) alcançou uma precisão global de 56,3%. A avaliação visual do mapa temático gerado (Figura 19) demonstrou uma boa classificação da classe Corpos d'água. No entanto, observou-se elevada confusão entre as classes Vegetação de Grande Porte e Edificações, resultando na classificação incorreta de diversas áreas vegetadas como estruturas construídas.


Além disso, áreas correspondentes à Vegetação de Pequeno Porte, especialmente gramíneas, foram frequentemente classificadas como Solo Exposto. Também foi possível identificar confusões entre as classes Vias, Solo Exposto e Vegetação de Pequeno Porte, evidenciando a dificuldade do algoritmo em diferenciar feições com características altimétricas semelhantes.

A análise da matriz de confusão (Figura 20) indicou que a classe Edificação apresentou o maior número de amostras corretamente classificadas. Contudo, ao comparar esses resultados com o mapa temático, verificou-se que parte desse desempenho pode estar relacionada à classificação incorreta de áreas de Vegetação de Grande Porte como edificações. A classe Vegetação de Grande Porte apresentou o segundo maior número de amostras corretamente classificadas, demonstrando o potencial dos atributos topográficos na identificação de feições com maior expressão vertical.

O desempenho obtido pelo *Extra Trees* foi semelhante ao observado para o RF, indicando que ambos os algoritmos apresentaram limitações quando empregados exclusivamente com atributos derivados do terreno. Embora o *Extra Trees* seja reconhecido pela elevada capacidade de generalização decorrente da maior aleatoriedade na construção das árvores de decisão (GEURTS; ERNST; WEHENKEL, 2006), os resultados evidenciam que a semelhança altimétrica entre determinadas classes reduziu o poder discriminatório do modelo. Resultados semelhantes foram relatados por Samat *et al.* (2018), que destacam que o desempenho do algoritmo é potencializado quando informações espectrais e espaciais são utilizadas de forma conjunta.


Os resultados obtidos reforçam que atributos como MDT, nDSM e declividade são eficientes para representar diferenças de altura entre os alvos, favorecendo a identificação de classes como Edificações e Vegetação de Grande Porte. Entretanto, sua utilização isolada mostrou-se insuficiente para separar classes que apresentam comportamento altimétrico semelhante, indicando que a integração entre atributos espectrais e topográficos constitui uma estratégia mais adequada para aumentar a precisão da classificação, conforme observado por Park *et al.* (2022) e Aydin e Sefercik (2025).

Figura 19 – Mapa Temático: MDT, nDSM e Declividade por meio do algoritmo ET



Fonte: Autor, 2026.

Figura 20 – Matriz de confusão: MDT, nDSM e Declividade por meio do algoritmo ET



Fonte: Autor, 2026.

5.3.4 Comparação entre GMM, RF e ET utilizando o empilhamento de MDT, nDSM e declividade

A comparação entre os algoritmos *Gaussian Mixture Model* (GMM), *Random Forest* (RF) e *Extra Trees* (ET) aplicados aos atributos derivados do terreno revelou desempenho inferior ao observado nas classificações baseadas em informações espectrais. O algoritmo *Extra Trees* apresentou a maior precisão entre os métodos avaliados, alcançando 56,3%, seguido pelo *Random Forest*, com 56,1%, e pelo *Gaussian Mixture Model*, com 49,3%. Embora a diferença entre RF e ET tenha sido reduzida, ambos apresentaram desempenho superior ao GMM.

Os resultados demonstraram que o GMM apresentou maior tendência à generalização da classe Vias, ocasionando elevada confusão com as classes Solo Exposto, Vegetação de Pequeno Porte e Corpos d'água. Esse comportamento pode ser explicado pelas limitações do

algoritmo na separação de classes que apresentam elevada sobreposição nas variáveis de entrada, conforme discutido por Bishop (2006).

Os algoritmos RF e ET apresentaram resultados semelhantes, com melhor capacidade para identificar as classes Edificação, Vegetação de Grande Porte e Corpos d'água. Esse comportamento está de acordo com Breiman (2001), Belgiu e Drăguț (2016) e Geurts, Ernst e Wehenkel (2006), que destacam a eficiência dos algoritmos baseados em árvores de decisão na modelagem de relações complexas entre os atributos. Entretanto, ambos apresentaram dificuldades na diferenciação entre Solo Exposto, Vegetação de Pequeno Porte e Vias, sugerindo que essas classes possuem características altimétricas pouco distintas.

Uma característica comum entre os três métodos foi a dificuldade na classificação da classe Vegetação de Pequeno Porte, que apresentou baixos índices de acerto independentemente do algoritmo empregado. Além disso, embora a classe Corpos d'água tenha apresentado melhor desempenho nos algoritmos RF e ET, ainda foram observadas confusões relevantes com outras classes.

De maneira geral, os resultados indicam que os atributos derivados do terreno, embora eficientes para a identificação de classes associadas a diferenças altimétricas mais evidentes, como Edificações e Vegetação de Grande Porte, apresentam limitações quando utilizados isoladamente para discriminar classes com características topográficas semelhantes. Esses resultados corroboram os estudos de Park *et al.* (2022) e Aydin e Sefercik (2025), que demonstram que a integração entre informações espectrais e topográficas proporciona maior capacidade de discriminação entre classes de cobertura e uso da terra, resultando em classificações mais precisas do que a utilização isolada desses conjuntos de atributos.

5.4 RGB e Terreno

Com o objetivo de aprimorar a classificação baseada exclusivamente nas bandas espectrais RGB, foram incorporados atributos topográficos derivados do terreno ao conjunto de dados de entrada. Para isso, foi realizado o empilhamento das bandas RGB com o Modelo Digital do Terreno (MDT), o *normalized Digital Surface Model* (nDSM) e a declividade, gerando um único arquivo multibanda contendo informações espectrais e topográficas.

A integração desses atributos buscou aumentar a capacidade dos algoritmos em diferenciar classes com características espectrais semelhantes, mas com comportamentos estruturais distintos. Enquanto as bandas RGB fornecem informações relacionadas à resposta espectral dos alvos, as variáveis derivadas do terreno representam características como altura

e relevo, permitindo uma descrição mais completa da superfície terrestre. Estudos recentes demonstram que a combinação de atributos espectrais e topográficos contribui para reduzir ambiguidades entre classes e aumentar a precisão da classificação da cobertura e uso da terra, especialmente em ambientes urbanos (PARK *et al.*, 2022; AYDIN; SEFERCIK, 2025).

5.4.1 RGB, MDT, nDSM e Declividade por meio do algoritmo GMM


O *Gaussian Mixture Model* (GMM) alcançou uma precisão global de 78,0%. A análise visual do mapa temático gerado (Figura 21) demonstrou uma melhora significativa em relação aos experimentos realizados exclusivamente com atributos espectrais ou topográficos, evidenciando que a integração entre informações RGB e variáveis derivadas do terreno contribuiu para aumentar a capacidade de discriminação entre as classes.

Apesar da melhoria geral, observou-se que diversos pixels pertencentes à classe Sombra foram classificados incorretamente como Corpos d'água. Além disso, verificou-se considerável confusão entre as classes Solo Exposto e Vias, resultando na classificação de áreas de Solo Exposto como vias. Por outro lado, as classes Vegetação de Pequeno Porte, Vegetação de Grande Porte e Corpos d'água apresentaram boa representação espacial no mapa classificado.

A análise da matriz de confusão (Figura 22) indicou que as classes Edificação e Vegetação de Grande Porte apresentaram os melhores resultados, ambas registrando 184 amostras corretamente classificadas. Em contrapartida, a classe Solo Exposto apresentou o pior desempenho, sendo frequentemente confundida com a classe Vias.


O aumento da precisão em relação aos experimentos anteriores demonstra que a combinação entre atributos espectrais e topográficos ampliou o poder discriminatório do *GMM*, reduzindo parte das ambiguidades observadas quando essas informações foram utilizadas de forma isolada. A integração de variáveis relacionadas à resposta espectral, altura e relevo permite representar de forma mais completa as características dos diferentes alvos, favorecendo a separação entre classes de cobertura e uso da terra. Resultados semelhantes foram relatados por Park *et al.* (2022) e Aydin e Sefercik (2025), que observaram ganhos de desempenho com a incorporação de atributos topográficos em classificações de ambientes urbanos.

Figura 21 – Mapa Temático: RGB, MDT, nDSM e Declividade por meio do algoritmo GMM



Fonte: Autor, 2026.

Figura 22 – Matriz de Confusão RGB, MDT, nDSM e Declividade por meio do algoritmo GMM



Fonte: Autor, 2026.

5.4.2 RGB, MDT, nDSM e Declividade – RF

O algoritmo *Random Forest* (RF) alcançou uma precisão global de 83,5%. A análise visual do mapa temático gerado (Figura 23) evidenciou uma melhora significativa na classificação das feições em comparação aos experimentos realizados com atributos espectrais e topográficos de forma isolada.


Observou-se um avanço expressivo na identificação da classe Sombra, sendo possível distinguir adequadamente áreas sombreadas associadas às laterais de edificações e a outros elementos urbanos. Além disso, as classes Edificação, Vegetação de Grande Porte e Corpos d'água apresentaram excelente representação espacial, demonstrando que a integração entre atributos espectrais e topográficos contribuiu para aumentar a capacidade de discriminação dessas categorias.

A análise da matriz de confusão (Figura 24) demonstrou que as classes Edificação e Vegetação de Grande Porte apresentaram os maiores índices de acerto entre as amostras

avaliadas. A classe Corpos d'água também apresentou bom desempenho, evidenciando que a combinação das bandas RGB com o MDT, o nDSM e a declividade reduziu parte das ambiguidades observadas nos experimentos anteriores.


O elevado desempenho obtido pelo *Random Forest* está de acordo com a literatura, que destaca sua elevada capacidade de modelar relações não lineares e integrar atributos de diferentes naturezas, tornando-o um dos algoritmos mais empregados em aplicações de sensoriamento remoto (BREIMAN, 2001; BELGIU; DRĂGUȚ, 2016). Além disso, os resultados corroboram os estudos de Park *et al.* (2022) e Aydin e Sefercik (2025), que demonstraram que a combinação de informações espectrais e topográficas proporciona ganhos significativos na classificação da cobertura e uso da terra, especialmente em ambientes urbanos caracterizados por elevada heterogeneidade.

Figura 23 – Mapa Temático - RGB, MDT, nDSM e Declividade por meio do algoritmo RF



Fonte: Autor, 2026.

Figura 24 – Matriz de Confusão RGB, MDT, nDSM e Declividade por meio do algoritmo RF



Fonte: Autor, 2026.

5.4.3 RGB, MDT, nDSM e Declividade por meio do algoritmo ET

O algoritmo *Extra Trees* (ET) apresentou a maior precisão entre os métodos avaliados, alcançando 84,5%. A avaliação visual do mapa temático gerado (Figura 25) demonstrou uma melhoria geral na classificação dos pixels quando comparada aos demais experimentos.

Assim como observado no algoritmo *Random Forest* (RF), verificou-se excelente identificação das classes Sombra e Corpos d'água, sendo possível distinguir adequadamente áreas sombreadas localizadas sobre ou próximas aos corpos hídricos. As classes Edificação, Vegetação de Grande Porte e Corpos d'água também apresentaram elevada qualidade de classificação, evidenciando o potencial da integração entre atributos espectrais e topográficos.


A análise da matriz de confusão (Figura 26) revelou que todas as classes apresentaram elevados índices de acerto. A classe Edificação registrou o maior número de amostras corretamente classificadas, enquanto a principal fonte de erro observada foi a confusão entre

as classes Vias e Solo Exposto, comportamento semelhante ao observado nos demais algoritmos.

O desempenho obtido demonstra que a combinação das bandas RGB com o MDT, o nDSM e a declividade aumentou significativamente o poder discriminatório do algoritmo, permitindo uma representação mais completa das características espectrais e estruturais dos alvos. O *Extra Trees* é reconhecido por sua elevada capacidade de generalização, decorrente da maior aleatoriedade empregada na construção das árvores de decisão, característica que contribui para reduzir a variância do modelo e melhorar sua capacidade de classificação (GEURTS; ERNST; WEHENKEL, 2006). Resultados semelhantes foram reportados por Samat *et al.* (2018), que destacam o elevado desempenho do algoritmo na classificação de imagens de alta resolução espacial quando múltiplos atributos são empregados.


Os resultados obtidos corroboram ainda os estudos de Park *et al.* (2022) e Aydin e Sefercik (2025), que demonstraram que a integração de informações espectrais e topográficas proporciona ganhos significativos na classificação da cobertura e uso da terra. Nesse contexto, a precisão alcançada pelo *Extra Trees* evidencia que a utilização conjunta desses atributos constitui uma estratégia eficiente para reduzir ambiguidades entre classes e aumentar a confiabilidade do mapeamento em ambientes urbanos.

Figura 25 – Mapa Temático: RGB, MDT, nDSM e Declividade por meio do algoritmo ET



Fonte: Autor, 2026.

Figura 26 – Matriz de Confusão RGB, MDT, nDSM e Declividade por meio do algoritmo ET



Fonte: Autor, 2026.

5.4.4 Comparação entre GMM, RF e ET utilizando RGB, MDT, nDSM e Declividade

A comparação entre os algoritmos *Gaussian Mixture Model* (GMM), *Random Forest* (RF) e *Extra Trees* (ET) utilizando a combinação das bandas RGB com os atributos topográficos demonstrou uma melhoria significativa no desempenho da classificação supervisionada em relação aos experimentos realizados apenas com dados espectrais ou exclusivamente com atributos derivados do terreno.

O algoritmo *Extra Trees* apresentou a maior precisão, atingindo 84,5%, seguido pelo *Random Forest*, com 83,5%, e pelo *Gaussian Mixture Model*, com 78,0%. Esses resultados evidenciam que a integração entre informações espectrais e topográficas ampliou a capacidade de discriminação entre as classes avaliadas, reduzindo ambiguidades observadas nos experimentos anteriores.

Uma característica comum observada nos três algoritmos foi o excelente desempenho das classes Edificação e Vegetação de Grande Porte, que apresentaram elevados índices de acerto tanto na análise visual dos mapas temáticos quanto nas matrizes de confusão. Além disso, verificou-se uma melhora considerável na identificação da classe Corpos d'água, especialmente nos algoritmos RF e ET. Esse comportamento demonstra que a combinação entre informações espectrais e atributos estruturais favoreceu a separação de classes que apresentavam elevada similaridade quando apenas um conjunto de atributos era utilizado.

Embora o GMM tenha apresentado desempenho inferior aos algoritmos baseados em árvores de decisão, observou-se uma evolução significativa em relação aos experimentos anteriores, demonstrando que a inclusão dos atributos topográficos contribuiu para reduzir parte das confusões observadas nas classificações realizadas apenas com as bandas RGB. Esse comportamento está de acordo com Bishop (2006), que destaca que o desempenho do *Gaussian Mixture Model* depende diretamente da capacidade dos atributos de representar adequadamente a distribuição das classes.

Os algoritmos RF e ET apresentaram resultados bastante semelhantes, diferindo em apenas 1,0 ponto percentual de precisão. Ambos demonstraram elevada capacidade de discriminação entre as classes avaliadas, produzindo mapas temáticos mais homogêneos e com menor fragmentação espacial. Esses resultados corroboram os estudos de Breiman (2001), Belgiu e Drăguț (2016), Geurts, Ernst e Wehenkel (2006) e Samat *et al.* (2018), que destacam o elevado desempenho dos algoritmos baseados em árvores de decisão na classificação de imagens de sensoriamento remoto, especialmente quando múltiplos atributos são utilizados.

Entretanto, persistiram algumas confusões entre as classes Vias e Solo Exposto, indicando que essas categorias ainda apresentam características espectrais e topográficas semelhantes mesmo após a incorporação dos atributos derivados do terreno.

De maneira geral, os resultados demonstram que a integração das bandas RGB com o MDT, o nDSM e a declividade proporcionou os melhores desempenhos observados nesta pesquisa, evidenciando que a utilização conjunta de informações espectrais e topográficas aumenta significativamente a capacidade de discriminação dos algoritmos de classificação. Esse comportamento também foi observado por Park *et al.* (2022) e Aydin e Sefercik (2025), que verificaram ganhos expressivos de precisão decorrentes da combinação de atributos espectrais e topográficos em aplicações de classificação da cobertura e uso da terra em ambientes urbanos.

5.5 RGB, IHS, MDT, nDSM e Declividade

Com o objetivo de avaliar o potencial da integração entre diferentes conjuntos de atributos na classificação da cobertura e uso da terra, foram combinadas as bandas espectrais RGB, os componentes da transformação IHS e os atributos topográficos derivados do terreno. Para isso, foi realizado o empilhamento das bandas RGB com os componentes Intensidade (*Intensity*), Matiz (*Hue*) e Saturação (*Saturation*), o Modelo Digital do Terreno (MDT), o *normalized Digital Surface Model* (nDSM) e a declividade, gerando um único arquivo multibanda contendo informações espectrais e topográficas.

A integração desses atributos buscou ampliar a capacidade dos algoritmos em diferenciar classes com características espectrais semelhantes, mas com comportamentos estruturais distintos. Enquanto as bandas RGB e os componentes da transformação IHS fornecem informações relacionadas às características espectrais e radiométricas dos alvos, os atributos derivados do terreno representam diferenças de altura e relevo, permitindo uma caracterização mais completa da superfície terrestre. Estudos recentes demonstram que a combinação de atributos espectrais e topográficos pode aumentar a precisão da classificação da cobertura e uso da terra, especialmente em ambientes urbanos complexos (PARK *et al.*, 2022; AYDIN; SEFERCIK, 2025).

5.5.1 RGB, IHS, MDT, nDSM e Declividade por meio do algoritmo GMM


O *Gaussian Mixture Model* (GMM) alcançou uma precisão global de 80,6%. A análise do mapa temático gerado (Figura 27) evidenciou uma melhoria em relação aos experimentos realizados com atributos espectrais ou topográficos utilizados de forma isolada. Entretanto, a classe Corpos d'água apresentou dificuldades de classificação, sendo observada a classificação incorreta de diversos pixels pertencentes à classe Vias como Corpos d'água. Além disso, verificou-se elevada confusão entre as classes Corpos d'água e Sombra, bem como entre Vegetação de Grande Porte e Sombra. Também foram observadas confusões entre as classes Solo Exposto e Vias. Em contrapartida, a classe Vegetação de Pequeno Porte apresentou boa representação espacial no mapa classificado.

A análise da matriz de confusão (Figura 28) confirmou as tendências observadas na inspeção visual do mapa temático. As classes Vias e Solo Exposto apresentaram elevada confusão entre si, enquanto a classe Vegetação de Grande Porte foi frequentemente confundida com Vegetação de Pequeno Porte e Sombra. As classes Vegetação de Pequeno

Porte e Edificação registraram os maiores índices de acerto entre as amostras avaliadas, ao passo que a classe *Corpos d'água* apresentou o menor desempenho.


Os resultados demonstram que a integração das bandas RGB, dos componentes da transformação IHS e dos atributos topográficos aumentou a capacidade de discriminação do *GMM* em comparação aos experimentos anteriores. Entretanto, persistiram limitações na separação de classes que apresentam elevada similaridade espectral e estrutural, comportamento esperado para esse algoritmo quando as distribuições das classes apresentam sobreposição (BISHOP, 2006). Resultados semelhantes foram observados por Park *et al.* (2022) e Aydin e Sefercik (2025), que destacam que a combinação entre informações espectrais e topográficas melhora a classificação, embora ainda possam ocorrer ambiguidades entre classes com características semelhantes.

Figura 27 – Mapa Temático: RGB, IHS, MDT, nDSM e Declividade por meio do algoritmo GMM



Fonte: Autor, 2026.

Figura 28 – Matriz de Confusão: RGB, IHS, MDT, nDSM e Declividade por meio do algoritmo GMM



Legenda		
1 – Edificações;	5 – Vegetação de Grande Porte;	8 – Sombra.
2 – Solo Exposto;	6 - Vegetação de Pequeno Porte;	
3 – Vias;	7 – Corpos d'água;	

Fonte: Autor, 2026.

5.5.2 RGB, IHS, MDT, nDSM e Declividade por meio do algoritmo RF


O algoritmo *Random Forest* (RF) alcançou uma precisão global de 84,9%. A análise do mapa temático gerado pela classificação (Figura 29) evidenciou excelente desempenho na identificação da classe Edificação, sendo possível observar uma representação espacial homogênea nas áreas com maior concentração de estruturas construídas. A classe Solo Exposto apresentou o menor desempenho, com diversos pixels classificados incorretamente como Vias. Também foi observada uma melhora na classificação da classe Corpos d'água em relação aos experimentos anteriores. Entretanto, ainda foram identificados pixels pertencentes à classe Sombra classificados como Corpos d'água.

A análise da matriz de confusão (Figura 30) confirmou o elevado desempenho da classe Edificação, que apresentou o maior número de amostras corretamente classificadas. As classes Solo Exposto e Vias concentraram as principais confusões, sobretudo pela

classificação de amostras de Vias como Solo Exposto. Em contrapartida, a classe Corpos d'água apresentou melhora significativa em relação ao GMM, registrando 51 das 55 amostras corretamente classificadas.


Os resultados demonstram que a integração das bandas RGB, dos componentes da transformação IHS e dos atributos topográficos aumentou a capacidade de discriminação do *Random Forest*, favorecendo a identificação das diferentes classes de cobertura e uso da terra. Esse comportamento está de acordo com Breiman (2001) e Belgiu e Drăguț (2016), que destacam a elevada capacidade do algoritmo em modelar relações não lineares e integrar atributos de diferentes naturezas. Além disso, os resultados corroboram os estudos de Park *et al.* (2022) e Aydin e Sefercik (2025), que demonstraram que a combinação de informações espectrais e topográficas proporciona ganhos expressivos na classificação de ambientes urbanos. Entretanto, a persistência de confusões entre as classes Vias e Solo Exposto indica que essas categorias ainda apresentam características espectrais e estruturais semelhantes, mesmo com a incorporação dos atributos complementares.

Figura 29 – Mapa Temático: RGB, IHS, MDT, nDSM e Declividade por meio do algoritmo RF



Fonte: Autor, 2026

Figura 30 – Matriz de Confusão: RGB, IHS, MDT, nDSM e Declividade por meio do algoritmo RF



Fonte: Autor, 2026.

5.5.3 RGB, IHS, MDT, nDSM e Declividade por meio do algoritmo ET

O algoritmo *Extra Trees* (ET) alcançou uma precisão global de 86,1%, representando o melhor desempenho entre todos os experimentos realizados nesta pesquisa. A análise do mapa temático gerado (Figura 31) evidenciou elevada qualidade na classificação das feições, com destaque para as classes Sombra, Edificação e Vegetação de Pequeno Porte. A classe Sombra apresentou boa representação espacial, sendo possível identificar adequadamente áreas sombreadas associadas às edificações e à vegetação. A classe Edificação destacou-se pela elevada homogeneidade da classificação, permitindo uma representação detalhada das áreas construídas. Da mesma forma, a classe Vegetação de Pequeno Porte apresentou excelente distribuição espacial, com reduzida ocorrência de erros de classificação.


A análise da matriz de confusão (Figura 32) confirmou o elevado desempenho do algoritmo. As classes Edificação e Vegetação de Pequeno Porte apresentaram os maiores

índices de acerto entre as amostras avaliadas. A classe Corpos d'água também apresentou excelente desempenho, com 166 das 182 amostras corretamente classificadas. Em contrapartida, a classe Vias apresentou o menor índice de acerto, sendo frequentemente confundida com a classe Solo Exposto.

Os resultados demonstram que a combinação das bandas RGB, dos componentes da transformação IHS e dos atributos topográficos proporcionou o melhor desempenho do *Extra Trees*, evidenciando a elevada capacidade desse algoritmo em explorar informações complementares de diferentes naturezas. Esse comportamento está de acordo com Geurts, Ernst e Wehenkel (2006), que destacam a elevada capacidade de generalização do *Extra Trees*, bem como com Samat *et al.* (2018), que demonstraram o elevado potencial desse algoritmo na classificação de imagens de alta resolução espacial. Além disso, os resultados corroboram os estudos de Park *et al.* (2022) e Aydin e Sefercik (2025), que verificaram ganhos expressivos de precisão decorrentes da integração entre atributos espectrais e topográficos.


Apesar do elevado desempenho, ainda foram observadas confusões entre as classes Vias e Solo Exposto, indicando que essas categorias apresentam características espectrais e estruturais semelhantes. Ainda assim, a precisão alcançada pelo *Extra Trees* demonstra que a integração dos diferentes conjuntos de atributos foi eficaz para reduzir ambiguidades entre as classes e produzir mapas temáticos mais consistentes e homogêneos.

Figura 31 – Mapa Temático: RGB, IHS, MDT, nDSM e Declividade por meio do algoritmo ET



Fonte: Autor, 2026.

Figura 32 – Matriz de Confusão: RGB, IHS, MDT, nDSM e Declividade por meio do algoritmo ET



Fonte: Autor, 2026.

5.5.4 Comparação entre GMM, RF e ET utilizando RGB, IHS, MDT, nDSM e Declividade

A comparação entre os algoritmos *Gaussian Mixture Model* (GMM), *Random Forest* (RF) e *Extra Trees* (ET) utilizando o conjunto completo de atributos espectrais e topográficos demonstrou os melhores resultados obtidos nesta pesquisa. A integração das bandas RGB, dos componentes da transformação IHS e dos atributos derivados do terreno proporcionou maior capacidade de discriminação entre as classes de cobertura e uso da terra, reduzindo parte das ambiguidades observadas nos experimentos realizados com conjuntos de atributos individuais.

O algoritmo *Extra Trees* apresentou o melhor desempenho geral, alcançando uma precisão de 86,1%, seguido pelo *Random Forest*, com 84,9%, e pelo *Gaussian Mixture Model*, com 80,6%. Embora todos os algoritmos tenham apresentado melhoria em relação às etapas

anteriores, os métodos baseados em árvores de decisão demonstraram maior capacidade para explorar a complementaridade entre os atributos espectrais e topográficos, resultando em classificações mais precisas e espacialmente mais homogêneas.

Uma característica comum observada nos três algoritmos foi a persistência da confusão entre as classes Vias e Solo Exposto, indicando que essas categorias ainda apresentam características semelhantes, mesmo quando diferentes conjuntos de atributos são utilizados de forma integrada. Também foram observadas confusões entre as classes Vegetação de Grande Porte, Vegetação de Pequeno Porte e Sombra, embora em menor intensidade quando comparadas aos experimentos anteriores.

Entre as classes com melhor desempenho, destacou-se a Edificação, que apresentou elevados índices de acerto nos três algoritmos, especialmente nos modelos RF e ET. A classe Corpos d'água, que apresentou limitações nos experimentos utilizando apenas atributos espectrais ou apenas atributos topográficos, apresentou melhora expressiva com a integração de todos os atributos, principalmente nos algoritmos RF e ET. Esses resultados demonstram que a combinação de informações espectrais, radiométricas e topográficas favoreceu a separação de classes que anteriormente apresentavam elevada similaridade.

O desempenho inferior do GMM em relação aos algoritmos baseados em árvores de decisão pode estar relacionado às premissas probabilísticas do modelo, que assumem distribuições gaussianas para representar as classes (BISHOP, 2006). Em contrapartida, o RF e o ET apresentaram maior capacidade de modelar relações complexas entre os atributos, comportamento amplamente descrito por Breiman (2001), Belgiu e Drăguț (2016) e Geurts, Ernst e Wehenkel (2006). Além disso, os resultados obtidos corroboram os estudos de Samat *et al.* (2018), Park *et al.* (2022) e Aydin e Sefercik (2025), que destacam os benefícios da integração de atributos espectrais e topográficos e o elevado desempenho dos algoritmos baseados em árvores de decisão na classificação de imagens de alta resolução espacial.

De maneira geral, os resultados demonstram que a integração das bandas RGB, dos componentes da transformação IHS, do MDT, do nDSM e da declividade proporcionou os melhores desempenhos observados nesta pesquisa. Entre os métodos avaliados, o algoritmo *Extra Trees* destacou-se como a abordagem mais eficiente para o mapeamento da cobertura e uso da terra na Região Metropolitana do Recife, alcançando a maior precisão global e produzindo mapas temáticos com menor fragmentação e maior coerência espacial. Esses resultados evidenciam o potencial da utilização conjunta de atributos espectrais e topográficos para aplicações de classificação supervisionada em imagens de altíssima resolução espacial.

5.6 Vegetação de Grande Porte e Não Vegetação de Grande Porte


Além da classificação multiclasse da cobertura e uso da terra, foi realizada uma classificação binária com o objetivo de identificar áreas ocupadas por Vegetação de Grande Porte. Essa abordagem buscou avaliar o potencial das imagens de altíssima resolução espacial para aplicações voltadas ao mapeamento de árvores individualizadas, da arborização urbana e de remanescentes de florestas urbanas.

De modo geral, os resultados evidenciaram elevado potencial para a detecção da Vegetação de Grande Porte. Entretanto, o algoritmo *Gaussian Mixture Model* (GMM) apresentou limitações na diferenciação entre as classes Corpos d'água e Vegetação de Grande Porte, resultando em confusões recorrentes entre essas categorias. Nas classificações realizadas exclusivamente com as bandas RGB, observou-se que áreas de Vegetação de Pequeno Porte foram frequentemente classificadas como Vegetação de Grande Porte. Por sua vez, nas classificações baseadas apenas nos atributos derivados do terreno, diversos pixels pertencentes à classe Edificação foram classificados incorretamente como Vegetação de Grande Porte, evidenciando as limitações da utilização isolada dessas variáveis.

A integração das bandas RGB com os atributos topográficos proporcionou melhora significativa na identificação da Vegetação de Grande Porte. Nesse cenário, verificou-se maior capacidade de distinguir áreas edificadas, que passaram a ser classificadas predominantemente como Não Vegetação de Grande Porte. Entretanto, persistiram confusões entre as classes Sombra e Vegetação de Grande Porte nos três algoritmos avaliados, indicando que essas feições ainda apresentam elevada similaridade para os classificadores.

De maneira geral, os resultados demonstram que a utilização de imagens de altíssima resolução espacial, associadas à integração de atributos espectrais e topográficos, constitui uma abordagem eficiente para o mapeamento da Vegetação de Grande Porte em áreas densamente urbanizadas. Essa estratégia possibilitou a identificação de árvores individualizadas e a delimitação de remanescentes de florestas urbanas, com melhor desempenho observado no empilhamento das bandas RGB com os atributos derivados do terreno. Esses resultados estão em consonância com os estudos de Park *et al.* (2022), Aydin e Sefercik (2025) e Roy, Byrne e Pickering (2012), que destacam a importância da integração de diferentes conjuntos de atributos para aumentar a precisão do mapeamento da vegetação urbana e subsidiar ações de planejamento e gestão ambiental.

A Figura 33 apresenta os resultados obtidos para a classificação binária da Vegetação de Grande Porte e Não Vegetação de Grande Porte.

Figura 33 – Mapa Temático gerado pelas classificações GMM, RF e ET

Fonte: Autor, 2026.

A análise das matrizes de confusão (Figura 34) e das precisões globais obtidas por cada algoritmo (Figura 35) permitiu avaliar detalhadamente o desempenho dos modelos na classificação binária entre Vegetação de Grande Porte e Não Vegetação de Grande Porte.

Na classificação utilizando exclusivamente as bandas RGB, verificou-se que a classe Não Vegetação de Grande Porte apresentou o maior número de amostras classificadas incorretamente como Vegetação de Grande Porte. Entre os algoritmos avaliados, o *Random Forest* (RF) apresentou o melhor desempenho, seguido pelo *Extra Trees* (ET) e pelo *Gaussian Mixture Model* (GMM).

Na classificação baseada apenas nos atributos derivados do terreno, observou-se que ambas as classes apresentaram níveis semelhantes de confusão. Apesar disso, a maior parte das amostras foi corretamente classificada pelos algoritmos. Assim como no experimento utilizando apenas as bandas RGB, o RF apresentou a maior precisão entre os métodos avaliados.

Por fim, a classificação utilizando o empilhamento das bandas RGB com os atributos derivados do terreno apresentou os melhores resultados, evidenciando uma redução significativa das confusões entre as classes e um aumento no número de amostras corretamente classificadas. As precisões obtidas pelos três algoritmos foram bastante semelhantes, com destaque para o GMM e o ET, que alcançaram a maior precisão global, de 97,6%.

Os resultados demonstram que a integração entre atributos espectrais e topográficos aumentou significativamente a capacidade de discriminação entre Vegetação de Grande Porte e Não Vegetação de Grande Porte. Esse comportamento reforça o potencial da utilização conjunta desses atributos para o mapeamento da vegetação arbórea em ambientes urbanos, possibilitando a identificação mais precisa de árvores individualizadas e de remanescentes florestais urbanos. Esses achados corroboram os estudos de Park *et al.* (2022), Aydin e Sefercik (2025) e Roy, Byrne e Pickering (2012), que destacam a importância da combinação de diferentes tipos de atributos para aprimorar o mapeamento da vegetação urbana.

Figura 34 – Matrizes de confusão dos modelos GMM, RF e ET

	GMM			RF			ET		
RGB	True/ pred	1	2	True/ pred	1	2	True/ pred	1	2
	1	1207	30	1	1413	73	1	1171	66
	2	161	1089	2	133	1367	2	112	1138
Terreno	True/ pred	1	2	True/ pred	1	2	True/ pred	1	2
	1	1093	144	1	1339	147	1	1110	127
	2	147	1103	2	156	1344	2	134	1116
RGB + Terreno	True/ pred	1	2	True/ pred	1	2	True/ pred	1	2
	1	1220	17	1	1456	30	1	1214	23
	2	41	1209	2	42	1458	2	35	1215

Fonte: Autor, 2026.

Figura 35 – Precisão Global dos modelos GMM, RF e ET

	Precisão		
	GMM	RF	ET
RGB	92,3%	93,1%	92,8%
Terreno	88,3%	89,9%	89,5%
RGB + Terreno	97,7%	97,6%	97,7%

Fonte: Autor, 2026.

6. CONCLUSÕES E RECOMENDAÇÕES

6.1 Conclusões

O presente trabalho teve como objetivo avaliar o desempenho dos algoritmos *Gaussian Mixture Model* (GMM), *Random Forest* (RF) e *Extra Trees* (ET) na classificação supervisionada de imagens de altíssima resolução espacial disponibilizadas pelo programa Pernambuco Tridimensional (PE3D), utilizando diferentes combinações de atributos espectrais e topográficos. Além da comparação entre os algoritmos e os diferentes conjuntos de atributos, buscou-se analisar o potencial dos produtos do PE3D para o mapeamento da cobertura e uso da terra e da vegetação arbórea na Região Metropolitana do Recife.

Os resultados demonstraram que a utilização apenas das bandas RGB apresentou resultados satisfatórios, com precisões variando entre 69,5% e 71,5%, sendo o algoritmo *Extra Trees* o que apresentou o melhor desempenho nessa configuração. A utilização dos componentes da transformação IHS apresentou resultados semelhantes aos obtidos com as bandas RGB, alcançando uma precisão máxima de 71,6% com o algoritmo *Random Forest*.

Quando foram utilizados apenas os atributos topográficos derivados do MDT, do nDSM e da declividade, os resultados apresentaram os menores desempenhos do estudo, com precisões variando entre 49,3% e 56,3%. Esses resultados evidenciam que tais atributos possuem limitações quando empregados de forma isolada para a classificação da cobertura e uso da terra, embora tenham contribuído para a identificação de classes associadas a diferenças estruturais mais evidentes, como Edificações e Vegetação de Grande Porte.

A integração das bandas RGB com os atributos topográficos proporcionou melhora significativa no desempenho dos algoritmos, elevando as precisões para valores entre 78,0% e 84,5%. Esse resultado evidencia a importância da utilização conjunta de informações espectrais e topográficas para reduzir ambiguidades entre classes que apresentam características semelhantes.

Os melhores resultados do trabalho foram obtidos com o empilhamento das bandas RGB, dos componentes da transformação IHS e dos atributos derivados do terreno. Nessa configuração, os algoritmos alcançaram precisões superiores a 80%, destacando-se o algoritmo *Extra Trees*, com 86,1%, seguido pelo *Random Forest*, com 84,9%, e pelo *Gaussian Mixture Model*, com 80,6%. Esses resultados demonstram que a integração de múltiplas fontes de informação aumenta significativamente a capacidade dos algoritmos em discriminar as classes presentes na área de estudo.

Durante a análise das matrizes de confusão e dos mapas temáticos, observou-se que as classes Edificação, Vegetação de Grande Porte e Vegetação de Pequeno Porte apresentaram os melhores desempenhos na maioria dos experimentos realizados. Em contrapartida, as classes Vias e Solo Exposto apresentaram confusões recorrentes em praticamente todos os métodos avaliados. Também foram observadas confusões frequentes entre as classes Sombra e Corpos d'água, principalmente nas classificações realizadas apenas com atributos espectrais.

Além da classificação multiclasse, a classificação binária entre Vegetação de Grande Porte e Não Vegetação de Grande Porte apresentou resultados expressivos para o mapeamento da arborização urbana e de florestas urbanas. Os modelos GMM e *Extra Trees* alcançaram precisão de 97,6%, evidenciando o potencial das imagens de altíssima resolução espacial do PE3D para a identificação de árvores individualizadas e remanescentes florestais em ambientes urbanos.

De forma geral, os resultados demonstram que a utilização conjunta de atributos espectrais e topográficos constitui uma estratégia eficiente para a classificação supervisionada de imagens de altíssima resolução espacial. Entre os algoritmos avaliados, os métodos baseados em árvores de decisão apresentaram desempenho superior ao *Gaussian Mixture Model*, destacando-se o algoritmo *Extra Trees* como a abordagem mais eficiente para o conjunto de dados analisados. Os resultados obtidos evidenciam, ainda, o potencial dos produtos do PE3D para aplicações em sensoriamento remoto de alta resolução, contribuindo para o mapeamento da cobertura e uso da terra, da vegetação arbórea e para o suporte a ações de planejamento urbano, gestão ambiental e monitoramento territorial na Região Metropolitana do Recife.

6.2 Recomendações

Como recomendações para trabalhos futuros, sugere-se a inclusão de novos atributos derivados do relevo, como orientação de vertentes (*aspect*), curvatura e índices geomorfométricos, a fim de avaliar sua contribuição para a classificação da cobertura e uso da terra.

Recomenda-se também a avaliação de outros algoritmos de aprendizado de máquina, como *Extreme Gradient Boosting* (XGBoost) e *Light Gradient Boosting Machine* (LightGBM), bem como de métodos baseados em aprendizado profundo (*Deep Learning*), especialmente Redes Neurais Convolucionais (*Convolutional Neural Networks* – CNN), que vêm apresentando resultados promissores na classificação de imagens de altíssima resolução espacial.

Outra recomendação consiste na aplicação de técnicas de classificação orientada a objetos (*Object-Based Image Analysis* – OBIA), que podem reduzir o efeito de fragmentação observado nas classificações pixel a pixel e melhorar a delimitação espacial das feições urbanas.

Também se recomenda a investigação da contribuição de atributos de textura, como aqueles derivados da Matriz de Coocorrência dos Níveis de Cinza (*Gray Level Co-occurrence Matrix* – GLCM), visando aumentar a capacidade de discriminação entre classes com elevada similaridade espectral e estrutural.

Para o mapeamento da vegetação urbana, recomenda-se a realização de estudos voltados à estimativa da cobertura arbórea, à análise da conectividade ecológica e à quantificação de florestas urbanas, utilizando os produtos gerados pelo PE3D como base para o monitoramento ambiental e para o suporte às políticas públicas de planejamento urbano e gestão ambiental.

Por fim, recomenda-se a aplicação da metodologia desenvolvida neste trabalho em outras áreas contempladas pelo programa PE3D, abrangendo diferentes contextos urbanos e ambientais do estado de Pernambuco, com o objetivo de avaliar a capacidade de generalização dos modelos e ampliar o uso das imagens de altíssima resolução espacial em estudos de cobertura e uso da terra, vegetação arbórea e monitoramento territorial.

REFERÊNCIAS

AYDIN, M.; SEFERCIK, U. G. Improving land use/land cover classification accuracy using nDSM derived from UAV data and machine learning algorithms. **Earth Science Informatics**, v. 18, 2025. DOI: <https://doi.org/10.1007/s12145-025-01841-w>.

BELGIU, Mariana; DRĂGUT, Lucian. Random forest in remote sensing: A review of applications and future directions. **ISPRS Journal of Photogrammetry and Remote Sensing**, Amsterdam, v. 114, p. 24–31, 2016. DOI: <https://doi.org/10.1016/j.isprsjprs.2016.01.011>.

BEN MILED, I. *et al.* Deep learning and transfer learning approaches for land use and land cover classification using UAV imagery. **Remote Sensing**, 2025.

BISHOP, Christopher M. **Pattern Recognition and Machine Learning**. New York: Springer, 2006.

BLASCHKE, T. Object based image analysis for remote sensing. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 65, n. 1, p. 2–16, 2010. DOI: <https://doi.org/10.1016/j.isprsjprs.2009.06.004>.

BREIMAN, L. Random forests. **Machine Learning**, v. 45, n. 1, p. 5–32, 2001. DOI: <https://doi.org/10.1023/A:1010933404324>.

CAMARGO, F. F.; SANO, E. E.; ALMEIDA, C. M.; MURA, J. C.; ALMEIDA, T. A comparative assessment of machine-learning techniques for land use and land cover classification of the Brazilian tropical savanna using ALOS-2/PALSAR-2 polarimetric images. **Remote Sensing**, v. 11, n. 13, 2019. DOI: <https://doi.org/10.3390/rs11131600>.

GEURTS, P.; ERNST, D.; WEHENKEL, L. Extremely randomized trees. **Machine Learning**, v. 63, n. 1, p. 3–42, 2006. DOI: <https://doi.org/10.1007/s10994-006-6226-1>.

GOVERNO DE PERNAMBUCO. Secretaria de Recursos Hídricos e Saneamento. **PE3D – Pernambuco Tridimensional**. Recife, [s.d.]. Disponível em: <https://www.srhs.pe.gov.br/programas-acoes/pe3d>. Acesso em: 26 maio 2026.

MA, Lei; LIU, Yu; ZHANG, Xueliang; YE, Yuanxin; YIN, Gaofei; JOHNSON, Brian Alan; ZHU, Dong; MENG, Qingquan. Deep learning in remote sensing applications: A meta-analysis and review. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 152, p. 166–177, 2019. DOI: <https://doi.org/10.1016/j.isprsjprs.2019.04.015>.

MANGABEIRA, João Alfredo de Carvalho; AZEVEDO, Emílio Carlos de; LAMPARELLI, Rubens Augusto Camargo. **Avaliação do levantamento do uso das terras por imagens de satélite de alta e média resolução espacial**. Campinas: Embrapa Monitoramento por Satélite, 2003.

MAXWELL, Aaron E.; WARNER, Timothy A.; FANG, Fang. Implementation of machine-learning classification in remote sensing: An applied review. **International Journal of Remote Sensing**, Abingdon, v. 39, n. 9, p. 2784–2817, 2018. DOI: <https://doi.org/10.1080/01431161.2018.1433343>.

MENESES, P. R.; ALMEIDA, T.; SANO, E. E. **Processamento de imagens de sensoriamento remoto**. Brasília: Universidade de Brasília, 2012.

PARK, S. *et al.* Land use and land cover classification using UAV-derived variables and machine learning algorithms in urban environments. **Remote Sensing**, 2022.

PATEL, A. M.; SUTHAR, A. Experimental investigations of object-based urban land classification of multispectral IRS R2 image using supervised machine learning algorithms. **International Journal of Engineering Trends and Technology**, v. 70, n. 4, p. 135–145, 2022. DOI: <https://doi.org/10.14445/22315381/IJETT-V70I4P214>.

PELLETIER, Charlotte; VALERO, Silvia; INGLADA, Jordi. Assessing the robustness of Random Forests to map land cover with high resolution satellite image time series over large areas. **Remote Sensing of Environment**, Amsterdam, v. 187, p. 156–168, 2016. DOI: <https://doi.org/10.1016/j.rse.2016.10.010>.

ROY, Sudipto; BYRNE, Jason; PICKERING, Catherine. A systematic quantitative review of urban tree benefits, costs, and assessment methods across cities in different climatic zones. **Urban Forestry & Urban Greening**, v. 11, n. 4, p. 351–363, 2012. DOI: <https://doi.org/10.1016/j.ufug.2012.06.006>.

SAMAT, A.; PERSELLO, C.; LIU, S.; LI, E.; MIAO, Z.; ABUDUWAILI, J. Classification of VHR multispectral images using Extra Trees and maximally stable extremal region-guided morphological profile. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 11, n. 9, p. 3179–3195, 2018. DOI: <https://doi.org/10.1109/JSTARS.2018.2856911>.