



Fusão de Dados HSI, UHR e LiDAR para Caracterização do Ambiente Urbano

HSI, UHR, and LiDAR Data Fusion for the Urban Environment Characterization

Pâmela Carvalho Molina¹, Camila Souza dos Anjos Lacerda², Cláudia Maria de Almeida³ e Rodrigo de Campos Macedo⁴

¹ Universidade Federal do Paraná, Curitiba, Brasil. pamela.molina@ufpr.br.

ORCID: <https://orcid.org/0000-0003-2752-7438>

² Instituto Federal do Sul de Minas Gerais, Inconfidentes, Brasil. camila.lacerda@ifsuldeminas.edu.br.

ORCID: <https://orcid.org/0000-0002-6072-0881>

³ Instituto Nacional de Pesquisas Espaciais, São José dos Campos, Brasil. claudia.almeida@inpe.br.

ORCID: <https://orcid.org/0000-0002-6523-3169>

⁴ Universidade Federal do Paraná, Curitiba, Brasil. rodrigo.macedo@ufpr.br.

ORCID: <https://orcid.org/0002-5345-7149>

Recebido: 08.2023 | Aceito: 01.2025

Resumo: O estudo da forma urbana é sem dúvida a chave para avançar em direção às transformações sustentáveis. Entretanto, observações de Sensoriamento Remoto dentro desse domínio são complexas e desafiadoras, pois esses ambientes apresentam muitas características espectrais semelhantes, tornando a análise de imagens de áreas urbanas uma difícil tarefa. Embora os sistemas de sensores tenham sido aprimorados recentemente, eles ainda são incapazes de atingir um nível de detalhamento suficiente para analisar qualitativa e quantitativamente os alvos de interesse em uma imagem urbana. Nesse sentido, a fusão de dados de múltiplos sensores surge como solução viável para a detecção e interpretação detalhada dos elementos que compõem uma cena urbana. Este trabalho tem como objetivo realizar a fusão de dados utilizando uma imagem hiperespectral (HSI), uma imagem óptica RGB de ultra-alta resolução e dados de detecção e alcance de luz (LiDAR) para uma caracterização detalhada de um ambiente urbano do ponto de vista da cobertura do solo. Sete conjuntos de dados serão empregados, incluindo os dados separados RGB, HSI e LiDAR, bem como sua fusão. Este último é usado para demonstrar o potencial de integração de informações de vários sensores quando comparados com os resultados de acurácia de um único sensor. O algoritmo escolhido para realizar tais classificações é o *Random Forest*, uma vez que é possível manipular grandes quantidades de dados e alcançar acurácia satisfatória. A acurácia geral alcançada pelo conjunto de fusão de dados mostra-se significativamente superior à dos demais conjuntos, demonstrando que o uso combinado de dados de diferentes sensores refina os resultados da classificação, permitindo um nível preciso e detalhado de legenda de classificação.

Palavras-chave: Multissensor. Aprendizado de Máquina. Árvore de Decisão. Aplicações Urbanas.

Abstract: The study of the urban environment is undoubtedly the key to moving towards sustainable transformations. However, remotely sensed observations within such domain are complex and challenging, as these areas present many similar spectral characteristics, making image analysis of urban areas a difficult task. Although sensors systems have been recently improved, they are alone still unable to attain a sufficient level of detail to qualitatively and quantitatively analyze targets of interest in an urban image. In this sense, multisource data fusion emerges as a feasible solution for detailed detection and interpretation of elements that compose an urban scene. This work aims to perform data fusion using a hyperspectral image (HSI), an optical RGB ultra-high-resolution image, and Light Detection and Ranging (LiDAR) data for a detailed characterization of an urban environment under the perspective of land cover. Seven datasets will be employed, including the separate RGB, HSI, and LiDAR data as well as their fusion. The latter one is used to demonstrate the potential of integrating information from manifold sensors when compared with the accuracy results of a unique sensor. The algorithm chosen to perform such classifications is Random Forest since it can handle large amounts of data and achieve satisfactory accuracy. The overall accuracy reached by the data fusion set shows to be significantly superior to the ones obtained by the other datasets, demonstrating that the combined use of multisource data refines the classification results, allowing for an accurate and detailed level of classification legend.

Keywords: Multi-Sensor. Machine Learning. Decision Tree. Urban Applications.

1 INTRODUÇÃO

As áreas urbanas demandam dados de diversas fontes a fim de caracterizar sua superfície, monitorar seu desenvolvimento ao longo do tempo e detectar mudanças após inesperados eventos. Nesse contexto, a fusão de diversos dados de Sensoriamento Remoto (SR) apresenta um grande potencial para acompanhar as mudanças no uso e ocupação do solo. De acordo com Yang (2011), a fusão dos dados busca, resumidamente, combinar informações de variados sensores apoiados em estratégias de classificação para melhorar o desempenho do produto final (mapas temáticos), de forma que possa ser obtida uma caracterização detalhada e precisa da superfície terrestre.

De acordo com Kuras et al. (2021), os atuais sistemas sensores singularmente ainda são falhos para uma observação remota dos mais diferentes alvos presentes na superfície, o que consequentemente não alcança um nível de detalhamento suficiente para trabalho em áreas urbanas. No âmbito de tais refinamentos, convém mencionar as melhorias advindas com as resoluções espaciais submétricas, permitindo a identificação de alvos menores, o que é conhecido como ultra-alta resolução (*ultra-high-resolution – UHR*) (Pande et al., 2024). Os primeiros autores ressaltam ainda que o número de bandas dos sensores multiespectrais pode ser suficiente para identificar diferentes coberturas do solo. Entretanto, a capacidade de discriminação destes dados multiespectrais é limitada quando se trata da distinção de feições semelhantes, tais como nas análises detalhadas do ambiente urbano, no qual uma cena é composta por inúmeros tipos de materiais e com diferentes condições de intempéries. A partir de tal afirmação, podem ser utilizados os dados hiperespectrais, caracterizados por apresentarem bandas estreitas e contíguas.

Os sensores hiperespectrais normalmente apresentam ricas informações, caracterizadas por uma amostragem espectral detalhada em uma ampla faixa de comprimentos de onda, o que faz com que as imagens hiperespectrais (*hyperspectral images – HSI*) se tornem fontes de dados essenciais para lidar com a paisagem heterogênea e mista (Liu et al., 2019). Comparadas às imagens multiespectrais, as HSI têm várias vantagens, tais como a capacidade de viabilizar: a diferenciação de classes de uso e ocupação do solo; realização de operações espectrais precisas; identificação de materiais de superfície; remoção dos efeitos atmosféricos com maior acurácia; bem como a correlação de perfis espectrais com bancos de dados espectrais (Fan et al., 2017). Por outro lado, Gao et al. (2018) explica que devido à limitação do instrumento, é desafiador para os sensores hiperespectrais adquirirem simultaneamente HSI de alta resolução espacial, e consequentemente, apresentam *pixels* mistos, degradando bastante o processamento adicional nas aplicações de SR. A estratégia, nestes casos, é a remoção dos recursos redundantes e a preservação de informações úteis em um subespaço de baixa dimensão.

Dados oriundos de sensores ópticos ativos (LiDAR) podem ser utilizados para auxiliar na classificação do uso e ocupação do solo, especialmente se as coberturas de interesse tiverem alturas diferentes. O LiDAR se destaca por categorizar informações de altura dos objetos da cena (Ghamisi et al., 2017). Baseia-se em um método direto de captura de dados, já que o mesmo possui fonte de energia própria (LASER), tornando-o capaz de viabilizar a modelagem digital do terreno e da superfície (Fernandez-Diaz et al., 2016).

Além da riqueza de conteúdo espectral de diferentes sensores, é essencial conceber a possibilidade de extrair mais informações dos dados brutos. No caso particular deste trabalho, a extração de características foi realizada empregando a análise de componentes principais (*Principal Components Analysis – PCA*) e a fração de ruído mínimo (*Minimum Noise Fraction – MNF*) (Green et al., 1988). Essas transformações de imagem aprimoram certas características espectrais dos alvos de interesse, que seriam difíceis de discriminar usando apenas as bandas originais dos sensores. De acordo com Anjos et al. (2017a), a extração de atributos visa prospectar importantes informações do conjunto de dados (*dataset*) inicial. Tais atributos são utilizados no processo de classificação, visto que os classificadores trabalham como mineradores de dados, identificando, em meio a um amplo conjunto de entrada, quais atributos são necessários para determinar a separação entre as classes.

Para uma interpretação confiável de imagens urbanas, a fusão de dados é uma alternativa ideal, pois permite uma melhor detecção de elementos encontrados no espaço urbano, principalmente quando executada com classificadores automáticos de última geração (Anjos et al., 2019). Tal abordagem multidisciplinar visa à melhoria no desempenho de interpretação dos dados de origem para produzir representações com alta

qualidade de conteúdo. Zhang (2010) acrescenta que este campo de pesquisa tem se fortalecido devido à crescente quantidade de dados disponíveis, resultantes do desenvolvimento de novos sensores operando em diferentes faixas espectrais e com diversos modos de aquisição.

Os classificadores são modelos matemáticos denominados algoritmos, e um dos mais utilizados ultimamente são as árvores de decisão, mais especificamente o algoritmo denominado Floresta Aleatória, ou, em inglês, *Random Forest* (RF), pois têm demonstrado excelente desempenho na análise de bases de dados de SR que apresentam grande complexidade. O RF é construído de maneira aleatória, ou seja, para a classe de uma instância, o método combina, por meio de um mecanismo de votação, o resultado de várias árvores de decisão, e daí vem o nome do algoritmo: Floresta Aleatória. Ao final, cada árvore resulta em uma classificação ou um voto para uma classe. A classificação final é dada pelo rótulo que recebeu o maior número de votos entre todas as árvores da floresta (Rocha et al., 2024).

Com o uso do conjunto da fusão de dados e classificadores de ponta, podem ser alcançados níveis cada vez mais refinados de legenda nas classificações de uso e ocupação do solo. Anjos et al. (2017b) esclarecem que esses produtos com níveis mais detalhados de legenda podem ser úteis para estimar com precisão a reflectância de materiais de superfície e, assim, avaliar sua contribuição para o fenômeno das ilhas de calor urbanas e sua interferência no microclima urbano. Podem ser também proveitosos para discriminar entre coberturas vãs e permanentes, bem como detecção de piscinas irregularmente construídas, para fins de tributação imobiliária urbana. Além disso, podem ser utilizados na identificação de materiais com compostos agressivos à saúde e/ou suposta ou reconhecidamente cancerígenos e na avaliação da sua relação com a incidência de patologias, entre outras finalidades investigativas e fiscalizatórias.

Este artigo visa combinar dados multissensores com estratégias de classificação robustas para alcançar uma discriminação eficiente entre as classes de cobertura do solo urbano. O conjunto da fusão dos dados será analisado e comparado com outros seis, caracterizados individualmente por resolução espacial ultra-alta (RGB), HSI e LiDAR, além de combinações pareadas em cada *dataset*. Este trabalho não se compromete apenas a reunir dados de SR ativo e passivo, mas também realizar uma classificação de cobertura do solo urbana muito detalhada, baseada em um nível de legenda refinado composto por 17 classes, o que é ainda pouco explorado na literatura.

2 CLASSIFICAÇÃO DOS ESPAÇOS URBANOS

Os espaços urbanos se apresentam na atualidade com características diversas e são marcados por relações e funções cada vez mais interligadas, o que evidencia a complexidade na definição de uma abordagem única para sua delimitação. Apesar da dificuldade em se estabelecer distinções no meio urbano, este deve ser abordado com a devida cautela e de forma criteriosa, tendo em vista sua importância para fins de ações públicas e privadas no âmbito do planejamento territorial. A grande demanda de classificações por parte da academia, da administração pública e da sociedade em torno desse espectro temático não deixa dúvidas quanto à pertinência dessa discussão de forma contínua, considerando diversas abordagens e escalas (IBGE, 2017).

Neste sentido, Anjos (2016) explica que o SR dispõe de fontes e instrumentos para observação da Terra, os quais geram diferentes tipos de imagens aéreas ou orbitais com distintas resoluções (espacial, espectral, radiométrica e temporal). Em particular, Kuras et al. (2021) tratam acerca do uso do SR para a investigação da geometria urbana tridimensional, considerando-a crucial para a modelagem da morfologia urbana. No entanto, os desafios crescentes exigem uma solução tecnológica de ponta em termos de sensores e métodos de análise. Esses, por sinal, têm sido desenvolvidos e aprimorados continuadamente, aumentando o interesse em se identificar tipos de cobertura do solo urbano com base em propriedades espetrais, espaciais e estruturais (Kuras, 2021; Anjos, 2016).

Interligadas a esses avanços tecnológicos, encontram-se três temáticas em evidência atualmente: *Big Data*, *Data Mining* e *Data Fusion*. O termo *Big Data* está relacionado a conjuntos de dados de grande dimensionalidade. Este é um tema corrente em toda área de tecnologia, inclusive na área espacial, com o crescente volume de dados que descrevem a superfície terrestre gerados a bordo de inúmeros novos satélites, associado à popularização dos CubeSats, os nanossatélites e os picosatélites e de Veículos Aéreos Não Tripulados (VANTs). De igual forma, a geração massiva de dados também se encontra vinculada aos novos

sensores a bordo de aviões e ao *boom* de dados de geolocalização, em que cada indivíduo conectado ao seu telefone celular pode ser um produtor e consumidor de dados espaciais (Kuchler, 2021).

Tal volume de dados, que se impõe como uma nova realidade, requer o desenvolvimento de soluções direcionadas para o desafio de se lidar com alta dimensionalidade de forma robusta e efetiva. O que no passado recente era um grande problema, atualmente pode ser visto como uma solução, considerando-se as possibilidades de tratamento de *Big Data* que viabilizam a extração de informações em grandes volumes de dados. Essas abordagens ancoram-se invariavelmente em *Data Mining* (Mineração de Dados), cujo principal objetivo é a identificação de padrões ocultos em grandes massas de dados para transformá-los em informação (Kuchler, 2021; Anjos, 2016).

Em relação ao termo *Data Fusion* (Fusão de Dados), principal assunto deste trabalho, este refere-se à utilização de dados provenientes de diferentes fontes e que são integrados em uma mesma abordagem investigativa, contribuindo com uma decisão mais confiável em muitas tarefas, como detecção de mudanças, classificação do uso e ocupação do solo, entre outras vertentes (Li et al., 2022). Diante desse contexto, a Tabela 1 tem como objetivo a apresentação do estado da arte na área de classificação dos espaços urbanos, onde são detalhados os sensores utilizados, o número de faixas espectrais, a resolução espacial, o número de classes, o objetivo de cada trabalho e respectivas métricas de acurácia.

Tabela 1 - Estado da arte em classificação da cobertura do solo urbano.

Referências	Sensores (Nº de Bandas)	Res. Espacial	Nº de Classes	Objetivo e Índice Kappa / Acurácia / Exatidão Global
Lacerda (2020)	WV-2 (8); WV-3 (29)	2m; 1.24m	21	Abordagem Geobia para imagens UHR obtidas por aeronaves remotamente pilotadas e sensores satelitais com o uso de classificadores individuais e <i>ensemble</i> . (Kappa: 0,65 – 0,70; Exatidão: 70,2% – 76,6%).
Qiu et al. (2019)	Sentinel-2 (13)	10m	17	Classificação de cobertura do solo urbano baseada em zonas climáticas locais a partir de imagens multissazonais do Sentinel-2 com rede residual recorrente. (Kappa: 0,74 – 0,81; Exatidão: 77,9% – 84,0%).
Nistor et al. (2021)	CORONA KH-4B(Panchromatic image); SPOT 1(3); Sentinel-1A SAR(C-band); Sentinel-2 (13)	2m; 20m; 10m; 20m	16	Análise baseada em SR de mudanças na paisagem urbana na cidade de Bucareste, Romênia. (Kappa: 0,92; Exatidão: 94,1%).
Siddiqui (2020)	AVIRIS-NG (425)	8.1m	12	Caracterização de materiais urbanos em Dados AVIRIS-NG usando uma abordagem de filtragem ajustada por mistura. (Exatidão: 79,2% – 87,7%).
Li et al. (2024)	L8-OLI (11); Sentinel-2 (12); PlanetScope (4); WV-2 (8)	15m; 10m; 3m; 2m	13	Revisa e analisa diferentes fontes de dados, unidades de classificação e abordagens de mapeamento, para o mapeamento do uso da terra urbana. (Kappa: 0,48 – 0,62; Exatidão: 78,9% – 75,0%).
Yang et al. (2022)	Sentinel-2 (13)	0.2 m; 10m	10	Identificação de áreas úmidas urbanas por meio da classificação de cenas com SR utilizando aprendizado profundo: um estudo de caso em Shenzhen, China. (Kappa: 0,65 – 0,86; Exatidão: 70,6% – 88,7%).
Hu et al. (2021)	Sentinel-1 SAR; Sentinel-2 multispectral (13); MODIS(36)	10m; 10m; 500m	8	Generalização de modelos em aplicações de aprendizado profundo para mapeamento de uso do solo. (Acurácia: 0,42 – 0,71).
Costa et al. (2021)	ALOS-2/PALSAR-2; Sentinel-2A(13); PlanetScope(4);	-; 3m; 10m	7	Benefícios da combinação de dados ALOS/PALSAR-2 e Sentinel-2A na classificação das classes de cobertura do solo no planalto sul de Santa Catarina. (Kappa: 0,62 – 0,88; Exatidão: 68,9% – 90,3%).
Ouma et al. (2023)	L4-MSS (7); L5-TM (7); L7-ETM+ (8); L8-OLI (11)	60; 30m; 30m; 30m	6	Classificação da cobertura e uso do solo em ambientes urbanos, utilizando diferentes classificadores baseados em árvores de decisão. (Kappa: 0,70 – 0,94; Exatidão: 87,8% – 92,8%).

Elaboração: Os autores (2025).

Considerando-se que este trabalho objetiva identificar 17 classes de cobertura do solo urbano, os trabalhos listados na Tabela 1, compreendendo de 16 a 21 classes, atuam como balizadores no que diz respeito às métricas de exatidão e acurácia a serem obtidas nos experimentos aqui reportados. Neste sentido, os valores de Índice Kappa a serem considerados oscilam de 0,70 a 0,92, e os de exatidão global, de 70,2% a 94,1%.

3 MATERIAL E MÉTODOS

3.1 Área de Estudo

A área de estudo está localizada no campus da Universidade de Houston e seus arredores, no estado do Texas, EUA, e possui coordenadas geográficas centrais $29^{\circ}45'58,53''$ N e $95^{\circ}21'33,69''$ O. Os dados foram disponibilizados pelo *National Center for Airborne Laser Mapping* (NCALM) e *Hyperspectral Image Analysis Laboratory* (HIALab) da Universidade de Houston por meio do Concurso de Fusão de Dados (*Data Fusion Contest*), realizado anualmente pelo Instituto de Engenheiros Elétricos e Eletrônicos (*Institute of Electrical and Electronics Engineers* – IEEE), através da Sociedade de Geociências e Sensoriamento Remoto (*Geoscience and Remote Sensing Society* – GRSS).

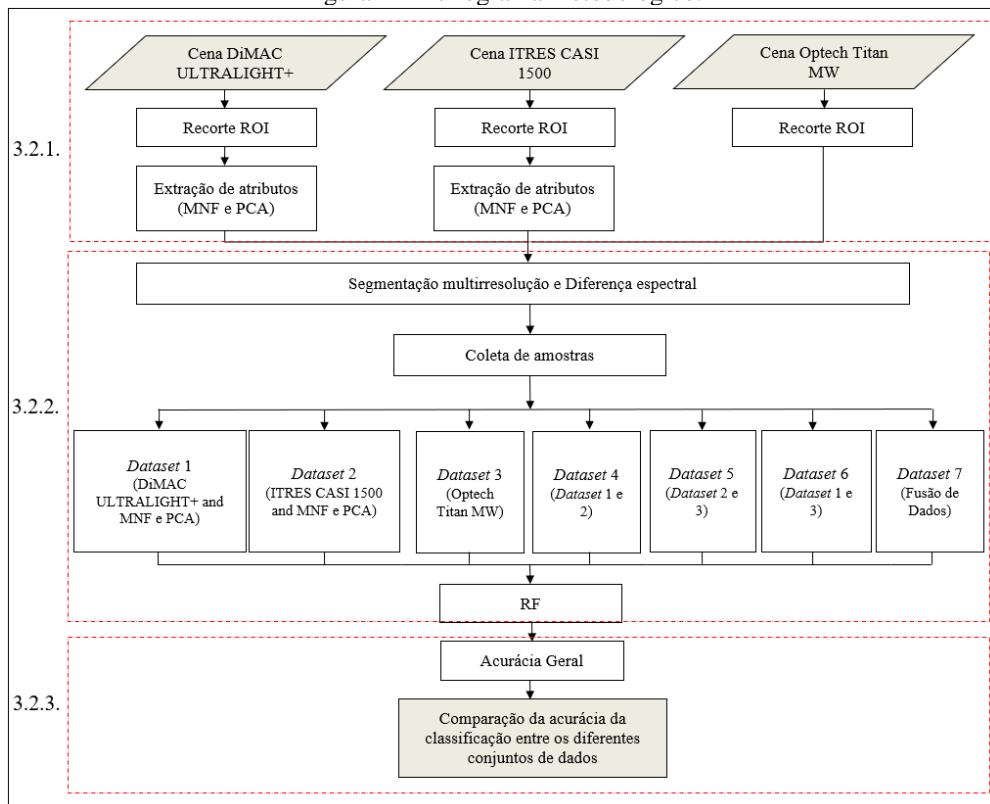
Os conjuntos de dados foram adquiridos em 16 de fevereiro de 2017, a bordo de uma aeronave Piper PA-31-350 Navajo Chieftan entre 16h31 e 18h18 GMT. Os sensores usados nesta pesquisa incluíram:

- Optech Titan MW com câmera digital integrada, sensor LiDAR multiespectral operando em três diferentes comprimentos de onda, sendo 1.550 nm, 1.064 nm e 532 nm, com resolução de 50 cm;
- DiMAC ULTRALIGHT+, caracterizado por gerar imagens RGB com resolução de 5 cm;
- ITRES CASI 1500, sensor hiperespectral com 48 bandas na região espectral variando de 380 nm a 1.050 nm, com resolução de 100 cm.

3.2 Desenvolvimento Metodológico

As seções a seguir apresentam os principais procedimentos metodológicos deste trabalho, que dizem respeito ao pré-processamento de imagens e extração de características, segmentação e classificação de dados e, finalmente, validação estatística dos resultados. Todas essas etapas consideram a avaliação dos dados de forma: (1) individual, compreendendo os conjuntos de dados constituídos pelo óptico (RGB), HSI e dados de elevação e intensidade (*intensity*) LiDAR separadamente; (2) pareada e (3) fusionada com os três conjuntos originais. A Figura 1 apresenta o fluxograma metodológico deste trabalho.

Figura 1 - Fluxograma metodológico.



Elaboração: Os autores (2025).

3.2.1 PRÉ-PROCESSAMENTO DAS IMAGENS E EXTRAÇÃO DOS ATRIBUTOS

A primeira etapa realizada no pré-processamento foi a extração da região de interesse (*Region of Interest – ROI*) da cena original nas imagens multiespectrais, hiperespectrais e nos dados LiDAR. A razão de se trabalhar com um subconjunto de imagens reside no alto custo computacional envolvido com a fusão de dados, que exige uma máquina com alta capacidade de memória e processamento. A desvantagem de se trabalhar com um ROI é a redução da diversidade de alvos, já que a imagem original possui 20 classes. No ROI, o número de alvos reduziu-se para 17 classes (incluindo-se sombra). Este processo foi realizado com a ferramenta *Spatial Subset*, utilizando-se o *software* Envi 5.3, modificando-se as dimensões das cenas conforme a Tabela 2.

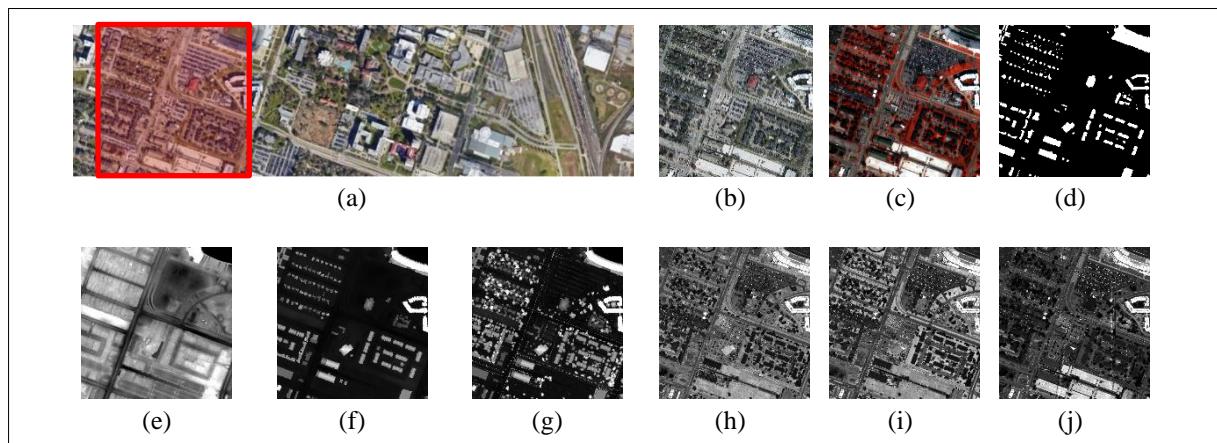
Tabela 2 - Dimensão das cenas após extração do ROI.

Cena	Dimensão original [Pixels]	Nova dimensão após recorte [Pixels]
DiMAC ULTRALiGHT+	47.680 x 12.020	11.920 x 12.020
ITRES CASI 1500	2.384 x 601	597 x 601
Optech Titan MW	4.768 x 1.202	1.193 x 1.202

Elaboração: Os autores (2025).

A Figura 2 mostra o resultado da extração do ROI.

Figura 2 - Visão geral do dataset. (a) Treinamento e teste (vermelho) destacado na cena original, (b) DiMAC ULTRALiGHT+ (3R2G1B) cena, (c) ITRES CASI 1500 (27R15G10B) cena, (d) a (j) Optech Titan MW scenes.



Elaboração: Os autores (2025).

As Figuras 2d a 2j mostram sete variações de dados LiDAR. As Figuras 2d e 2e correspondem a duas formas distintas de visualização de um modelo digital de elevação (*Digital Elevation Model – DEM*) com interpolação de 50 cm dentro de um raio de busca de 3 m, proporcionando uma melhor avaliação das estruturas presentes na cena (DEM_C123_3msr e DEM_C123_TLI, sendo que este último é obtido através de rede triangular irregular com interpolação linear). A Figura 2f é um modelo de elevação digital híbrido que combina retornos provenientes de edifícios ou do solo, submetidos a uma interpolação por krigagem com resolução de 50 cm e raio de 5 m (DEM+B_C123). A Figura 2g é um modelo digital de superfície (DSM), interpolado com resolução de 50 cm e raio de 5 m (DSM_C12). Além disso, as Figuras 2h (C1), 2i (C2) e 2j (C3) correspondem a diferentes intensidades associadas a três comprimentos de onda distintos: 1.550 nm, 1.064 nm e 532 nm, respectivamente. Elas também foram interpolados por krigagem, com resolução de 50 cm e raio de busca de 3 m.

Após o recorte das imagens, a extração de atributos foi realizada para dados multiespectrais e hiperespectrais. Tal procedimento tem como objetivo utilizar operações aritméticas para gerar novos atributos, destinados a separar as classes de interesse de forma mais eficaz. Entretanto, tem-se a preocupação da perda

de informações, sendo assim optou-se por utilizar a Fração Mínima de Ruído (*Minimum Noise Fraction – MNF*) e a Análise de Componentes Principais (*Principal Components Analysis – PCA*), uma vez que trabalham na redução de dimensionalidade sem perda de informações.

Neste sentido, as transformações MNF e PCA foram geradas por meio de suas ferramentas no *software* Envi 5.3 e utilizadas como atributos na classificação. No entanto, como o atributo MNF realiza o ordenamento conforme a qualidade da imagem, expressa pelo nível de ruído presente na cena, consideraram-se somente as componentes com o limiar de autovalores superiores a 5. Com isso, foram utilizadas as três primeiras componentes MNF para os dados DiMAC ULTRALIGHT+.

Em termos de PCA, o critério de seleção foi o valor do maior percentual de variação dos dados, ou seja, a quantidade de informação disponível. Todos os três componentes do PCA foram considerados no caso dos dados DiMAC ULTRALIGHT+, pois não apresentaram ruído. No entanto, apenas os primeiros seis componentes dos dados do ITRES CASI 1500 foram selecionados (Tabela 3). Vale ressaltar que os não selecionados tiveram valores zerados, que correspondem aos componentes com alto nível de ruído e, portanto, sem variação nos dados.

Tabela 3 - Dados de entrada e quantitativo de camadas para os *Datasets* de 1 a 7.

	Dados de Entrada	Camadas
<i>Dataset 1</i>	Cena DiMAC ULTRALiGHT+	3
	Extração de atributos - MNF	3
	Extração de atributos - PCA	3
	Total	9
<i>Dataset 2</i>	Cena ITRES CASI 1500	48
	Extração de atributos - MNF	13
	Extração de atributos - PCA	6
	Total	67
<i>Dataset 3</i>	DEM_C123_3msr	1
	DEM_C123_TLI	1
	DEM+B_C123	1
	DSM_C12	1
	Intensity_C1	1
	Intensity_C2	1
	Intensity_C3	1
<i>Dataset 4</i>	Total	7
	<i>Dataset 1</i>	9
	<i>Dataset 2</i>	67
<i>Dataset 5</i>	Total	76
	<i>Dataset 2</i>	67
	<i>Dataset 3</i>	7
<i>Dataset 6</i>	Total	74
	<i>Dataset 1</i>	9
	<i>Dataset 3</i>	7
<i>Dataset 7</i>	Total	16
	<i>Dataset 1</i>	9
	<i>Dataset 2</i>	67
	<i>Dataset 3</i>	7
Total		83

Elaboração: Os autores (2025).

3.2.2 SEGMENTAÇÃO E CLASSIFICAÇÃO DOS DADOS

O objetivo da segmentação é a partição de imagens, agregando *pixels* e grupos de *pixels* em segmentos homogêneos, chamados de regiões ou objetos. A segmentação multirresolução adotada é baseada na abordagem de crescimento de região, que examina *pixels* vizinhos de *pixels*-sementes iniciais e determina se os *pixels* vizinhos devem ou não ser adicionados à região. O processo é iterativo, baseado em definições de homogeneidade em combinação com técnicas de otimização local e global (Baatz; Schäpe, 2000). Esta classe de algoritmo tem sido adotada mundialmente em aplicações de SR (Blaschke, 2010). No entanto, tem a desvantagem de altos custos computacionais associados ao uso de dados de entrada de alta dimensão (Happ et al., 2009).

Esta pesquisa utiliza segmentação multirresolução seguida de um ajuste de diferença espectral. A primeira etapa é o algoritmo proposto por Baatz e Schäpe (2000), o qual utiliza essencialmente um procedimento de otimização heurística, que minimiza localmente a heterogeneidade média dos objetos na imagem para uma determinada resolução em toda a cena (Matsuoka, 2007). A segmentação pode ser realizada em múltiplas resoluções por uma variação dos parâmetros de segmentação (Leonardi, 2010). Esses parâmetros são divididos em escala, forma, compacidade e suavidade. Após definir tais parâmetros, também é necessário atribuir pesos às imagens de acordo com seu grau de importância. Quanto maior o peso atribuído a uma camada de imagem, maior o papel dessa camada durante o processo de ajuste (Definiens, 2012).

Ambas as etapas de segmentação foram realizadas utilizando o *software* eCognition Developer versão 9.0, 64 bits. Ressalta-se que os procedimentos foram realizados na imagem com melhor resolução espacial (DiMAC ULTRALIGHT+ com resolução de 5cm), a fim de proporcionar ao intérprete uma melhor visualização da cena e, consequentemente, garantir maior precisão nas amostras. Os parâmetros de segmentação empregados são fornecidos na Tabela 4.

Tabela 4 - Parâmetros de segmentação.

Parâmetros	Valores
Escala	12
Forma	0,3
Compacidade	0,5
Peso	1 (todas as bandas)
Diferença espectral	3

Elaboração: Os autores (2025).

O processo de segmentação em duas etapas totalizou 983.224 segmentos. Após a segmentação, foram coletados pontos amostrais para 17 classes encontradas no ROI da imagem, conforme apresentado na Tabela 5.

Vale destacar que a coleta dos segmentos amostrais foi igual para os sete diferentes conjuntos de dados, buscando atender uma “regra de ouro” disposta por Lillesand et al. (2015) e Congalton e Green (2009), os quais sugerem que o tamanho do conjunto amostral adequado para cada projeto deve ter um planejamento para coleta de no mínimo 50 amostras por classe para mapas de menos de 1 milhão de acres em tamanho e menos de 12 classes. Congalton e Green (2009) complementam que grandes áreas ou mapas mais complexos devem receber de 75 a 100 amostras por classe. No entanto, como pode ser notado na Tabela 5, nem todas as classes conseguiram atingir o objetivo, visto que algumas apresentaram quantidade reduzida de segmentos, o que não comporta um grande número de amostras.

As amostras foram coletadas com o auxílio de um mapa de referência fornecido em conjunto pelo NCALM e HIALab, conforme mostrado na Figura 2. Ressalta-se que a classe sombra não foi incluída no mapa de referência.

Tabela 5 - Coleta de amostras.

Classe	Conjunto de treinamento	Cor da classe
Água	10	
Árvore Decídua	68	
Árvore Perenifólia	67	
Assentos de Estádio	58	
Calçada	58	
Carro	62	
Edifício Não Residencial	74	
Edifício Residencial	74	
Estacionamento Não Pavimentado	10	
Estacionamento Pavimentado	45	
Faixa de Pedestre	30	
Grama Artificial	11	
Grama Estressada	59	
Grama Saudável	62	
Rua	72	
Sombra	11	
Via Principal	63	

Elaboração: Os autores (2025).

Figura 2 – Mapa de referência com a localização da área de estudo.



Elaboração: Os autores (2023).

Os atributos para a classificação dos sete conjuntos de dados foram gerados no eCognition 9.0 por meio da ferramenta “Atributos do objeto - Customizados” (*Object Features - Customized*). Alguns atributos customizados, como as razões de banda, reduzem muitas formas de ruído presentes em múltiplas bandas de imagens (Jensen & Cowen, 1999). Entre os atributos utilizados, alguns serão denominados de AC (Atributo Customizado), ao passo que os índices de vegetação OSAVI, NDVI, GRVI, GNDVI, DVI, bastante utilizados na literatura, mantiveram seus nomes originais, assim como os índices atrelados a assimetria, número de pixels, máxima diferença e direção principal.

O Índice de Vegetação Ajustado pelo Solo Otimizado (*Optimal Soil Adjustment Vegetation Index – OSAVI*) é utilizado como ferramenta para monitoramento de áreas com vegetação de baixa densidade em áreas de solo exposto. Por sua vez, o Índice de Vegetação por Diferença Normalizada (*Normalized Difference Vegetation Index – NDVI*) é eficaz para expressar o *status* e atributos quantificados da vegetação (Huang et al., 2021). Outro índice utilizado foi o Índice de Vegetação Verde-Vermelho (*Green Red Vegetation Index – GRVI*), o qual apresenta a capacidade de detectar mudanças na vegetação do dossel e em estádios fenológicos (Motohka et al., 2010). O Índice de Vegetação por Diferença Normalizada Verde (*Green Normalized Difference Vegetation Index – GNDVI*) foi sugerido para avaliar as variações de biomassa verde na escala do dossel (Zhou & Zhong, 2020; Ali et al., 2019), e, por fim, o Índice de Vegetação por Diferença (*Difference Vegetation Index – DVI*), que apesar de ser considerado simples, é sensível à vegetação (Martins, 2017).

As equações e as referências bibliográficas referentes aos atributos utilizados neste trabalho são apresentadas na Tabela 6.

Tabela 6 - Atributos utilizados nas classificações por RF.

Atributo	Equação	Referência
OSAVI	$\frac{\rho_{832nm} - \rho_{660nm}}{\rho_{832nm} + \rho_r + 0.16}$	Rondeaux et al. (1996)
NDVI	$\frac{\rho_{832nm} - \rho_{660nm}}{\rho_{832nm} + \rho_{660nm}}$	Rouse et al. (1974)
GRVI	$\frac{\rho_{545nm} - \rho_{660nm}}{\rho_{545nm} + \rho_{660nm}}$	Tucker (1979)
GNDVI	$\frac{\rho_{832nm} - \rho_{545nm}}{\rho_{832nm} + \rho_{545nm}}$	Gitelson et al. (1996)
DVI	$\frac{\rho_{832nm} - \rho_{660nm}}{\rho_{832nm} + \rho_{660nm}}$	Richardson e Wiegand (1977)
AC1	$AC1 = \frac{Brightness + Banda_{480nm}}{Banda_{660nm}}$	Leonardi (2010)
AC2	$AC2 = \frac{Brightness + Banda_{480nm}}{Banda_{725nm}}$	Adaptado de Leonardi (2010)
AC3	$AC3 = Brightness + Banda_{480nm} - Banda_{660nm}$	Leonardi (2010)
AC4	$AC4 = Brightness + Banda_{480nm} - Banda_{725nm}$	Adaptado de Leonardi (2010)
AC5	$AC5 = Brightness + Banda_{832nm}$	Leonardi (2010)

*Nota: ρ é a reflectância espectral.

Elaboração: Os autores (2025).

As formas originais das equações apresentadas na Tabela 6 correspondem ao uso das seguintes bandas: B8 azul (centrada em 480nm), B12 verde (centrada em 545nm), B21 vermelho (centrada em 660 nm) e B33 infravermelho próximo (centrada em 832 nm). No entanto, os dados do ITRES CASI 1500 possuem adicionalmente outras bandas na região espectral do azul B5 (centrada em 430 nm), do vermelho B19 (centrada em 630 nm) e outra banda do infravermelho próximo B27 (centrada em 950 nm). Logo, foram gerados cinco atributos customizados (AC), juntamente com OSAVI, NDVI, GRVI, GNDVI e DVI.

3.2.2.1 Classificação utilizando *Random Forest*

O princípio de funcionamento do RF baseia-se em uma grande coleção de árvores de decisão descorrelacionadas. A partir das amostras de treinamento originais, são criados diferentes conjuntos amostrais aleatórios, tamanhos conjuntos quantas forem as árvores de decisão, para permitir que árvores independentes sejam criadas (Anjos et al., 2017b). É utilizado um meta-algoritmo, visando melhorar classificação e regressão de modelos referentes à estabilidade e precisão da classificação. Este além de reduzir a variância, ajuda a evitar o *overfitting* (Son et al., 2009).

De acordo com Son et al. (2009) e Lopes et al. (2017), esse procedimento extrai aleatoriamente casos dos conjuntos de dados de treinamento originais, os quais são utilizados para construir cada uma das árvores de decisão que compõem a RF. Cada árvore classificadora é identificada como um componente preditor. RF constrói sua decisão contando os votos dos componentes preditivos em cada classe e então seleciona a classe bem-sucedida em termos do número acumulado de votos. Desta forma, todo o algoritmo inclui duas fases cruciais: a formação de cada árvore e a etapa de votação.

A primeira fase consiste em treinar cada árvore de decisão, e os subconjuntos de dados são selecionados do *dataset* de treinamento e definidos usando a estratégia de ensacamento aleatório (*bagging*). Em seguida, os dados de teste são classificados por maioria de votos. Cerca de um terço dos casos são deixados de fora das amostras de inicialização (*bootstrap*) e não são usados para construir uma árvore específica. Amostras deixadas fora da árvore de ordem *k* são executadas na *k*-ésima árvore para obter uma classificação (Lopes et al., 2017).

A RF foi gerada no Orange Canvas versão 3.25.0 com a indicação de 100 árvores para cada um dos sete *datasets*, totalizando assim 700 árvores. Vale destacar que o Orange Canvas é um *software* que possui uma biblioteca de objetos e rotinas para a programação visual baseado em componentes intitulados *widgets*. Estes oferecem funcionalidades básicas, como seleção de recursos, predição de treinamento, comparação de algoritmos de aprendizado, entre outros variados recursos. A partir disto, o usuário pode explorar interativamente as visualizações ou alimentar o subconjunto selecionado em outros *widgets*. É um *software* de código aberto e codificado em Python.

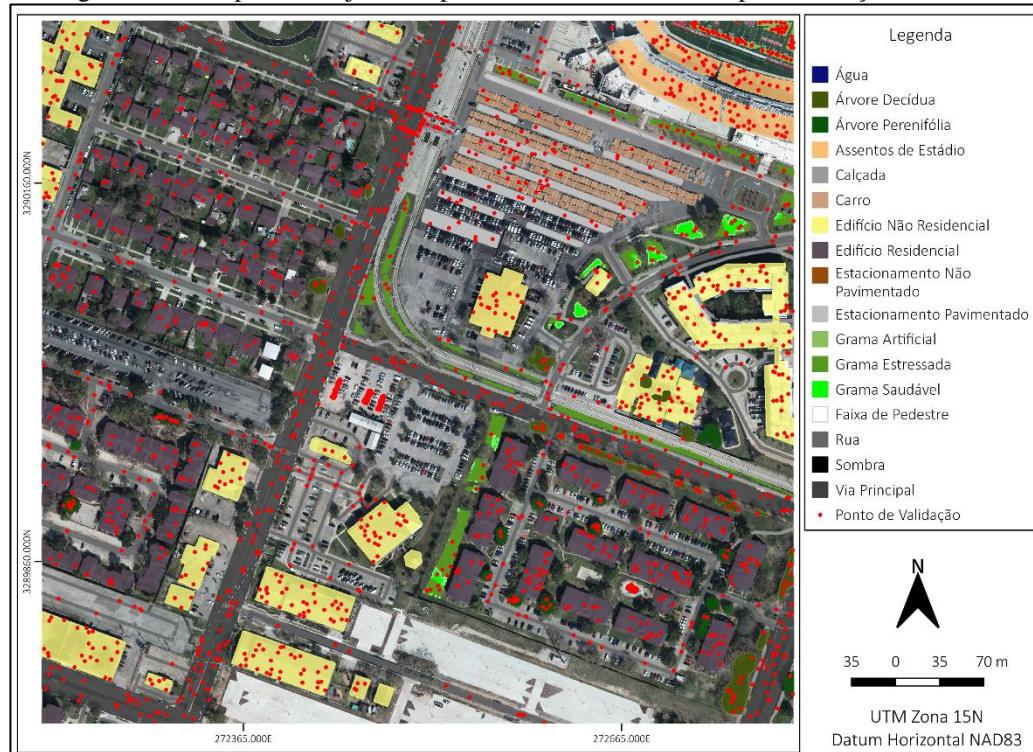
Os resultados com o método RF foram visualizados e validados no *software* QGis 3.4.12.

3.2.3 VALIDAÇÃO DOS DADOS

A validação dos resultados visa estimar a acurácia da classificação. Foram obtidas sete classificações, uma para cada um dos sete conjuntos de dados. Com base nessas classificações e no mapa de referência, foi possível validar os resultados de acordo com Congalton (1988), bem como Congalton e Green (2009).

A avaliação estatística é fundamental na análise de dados provenientes de quaisquer processos em que exista variabilidade, estando, assim, interessada nos métodos e processos quantitativos que servem para a coleta, organização, resumo, apresentação e análise desses dados, bem como na obtenção de conclusões válidas e na tomada de decisões a partir de tais análises (Panosso, 2019). Congalton e Green (2009) afirmam que, com um teste de hipótese Z, é possível comparar estatisticamente duas classificações e assim verificar qual produz a maior acurácia. Foi realizado um teste de hipótese Z, com nível de significância de 5%, entre pares de classificadores de um mesmo *dataset*, para avaliar se existe diferença significativa.

Figura 3 – Exemplo do conjunto de pontos aleatórios utilizados para validação.



Elaboração: Os autores (2025).

4 RESULTADOS E DISCUSSÕES

Os resultados das classificações utilizando os sete conjuntos de dados sob a análise dos mesmos atributos por meio do classificador RF serão apresentados a seguir, assim como os parâmetros considerados para a validação. Logo, a presente seção se divide em: resultados para *Dataset 1* (Seção 4.1), resultados para *Dataset 2* (Seção 4.2), resultados para *Dataset 3* (Seção 4.3), resultados para *Dataset 4* (Seção 4.4), resultados para *Dataset 5* (Seção 4.5), resultados para *Dataset 6* (Seção 4.6) e resultados para *Dataset 7* (Seção 4.7). Além disso, serão apresentados os resultados comparativos da exatidão global, erros de omissão e inclusão e teste de hipótese (Seção 4.8). Para uma análise visual das classificações, comparando-as com a referência, o leitor poderá recorrer ao mapa de referência, apresentado anteriormente na Seção 3.2.3.

4.1 Resultados do *Dataset 1*

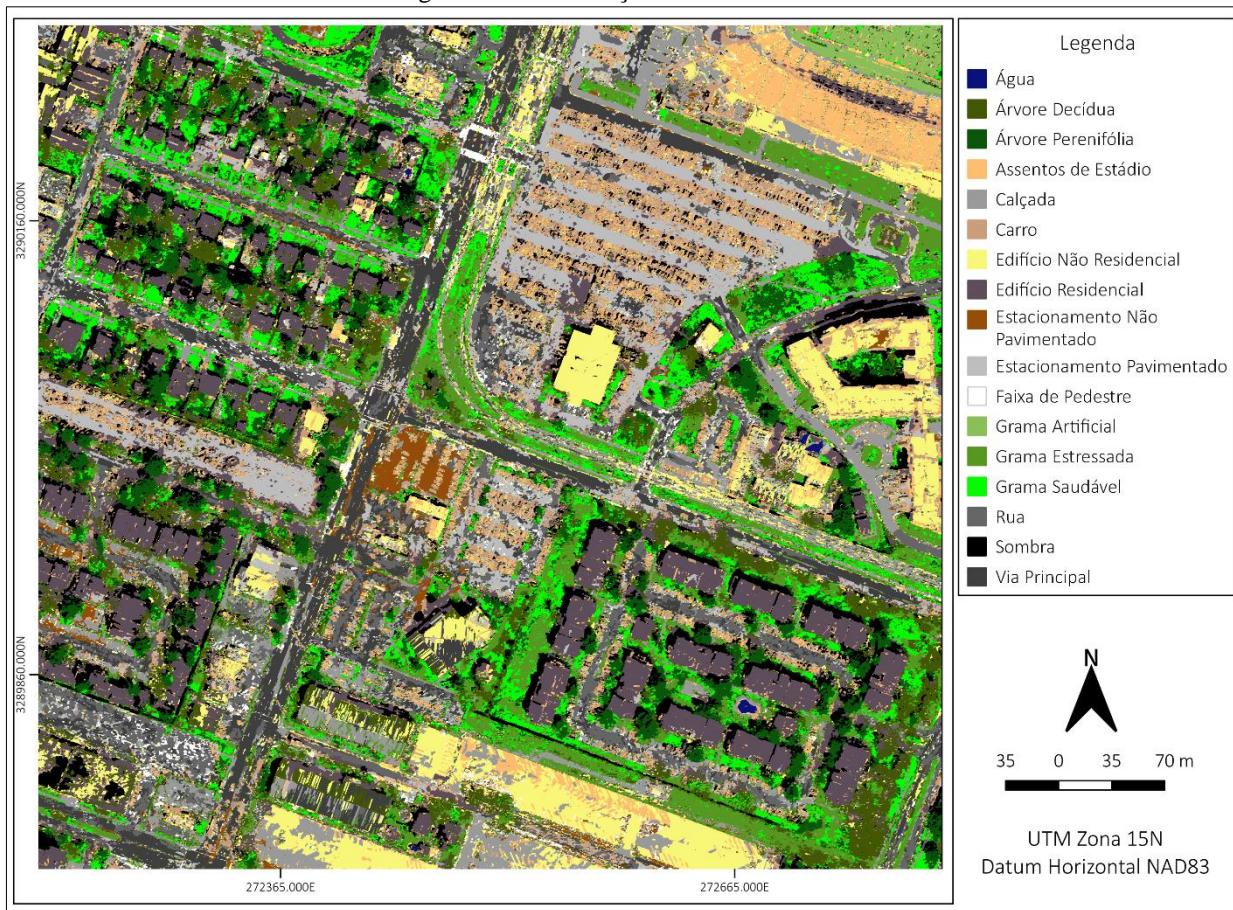
O resultado da classificação do *Dataset 1*, baseado na cena DiMAC ULTRALIGHT+, é apresentado na Figura 5. Neste caso, o *dataset* compreendeu 3 bandas originais deste sensor, 3 MNF e 3 componentes PCA, resultando em 9 camadas de entrada. A classificação do *Dataset 1* executada com o algoritmo RF resultou em uma exatidão global de 51,60%. As classes com os melhores percentuais de classificações corretas foram C15 (Estacionamento Não Pavimentado), com 100,00%, e C9 (Estacionamento Pavimentado), com 81,82% de acertos.

No entanto, algumas classes tiveram porcentagens de sucesso abaixo de 50%, como C1 (Gramado Artificial), 23,08% das quais confundidas com C6 (Gramado Saudável). Durán et al. (2018) explicam que a grama artificial é fabricada com materiais derivados de plásticos e polímeros com a finalidade de simular seu congênere natural. Portanto, no espectro visível, apresenta um tom de cor verde semelhante ao da grama natural, gerando confusão. Além disso, a classe C6 (Gramado Saudável) teve 54,88% dos casos classificados erroneamente como C4 (Árvore Caducifólia), devido às sutis diferenças em suas condições fitofisiológicas.

Tais confusões são compreensíveis quando se trabalha com um sensor de ultra-alta resolução espacial e baixa resolução espectral (RGB), dada a similaridade espectral nas respostas visíveis dos alvos. Para resolver este problema, é necessário refinar o espectro eletromagnético, tanto adicionando mais bandas espetrais quanto estreitando o alcance das bandas contíguas, como é o caso das imagens hiperespectrais do sensor ITRES CASI 1500.

Porém, outras confusões ocorreram com esses dados multiespectrais, como, por exemplo, a classe C7 (Via Principal), que teve 12,11% dos casos classificados erroneamente como C9 (Estacionamento Pavimentado); C8 (Edifício Não Residencial), que teve 11,11% de suas amostras classificadas erroneamente como C10 (Edifício Residencial); C11 (Estrada), que apresentou 24,86% dos casos erroneamente classificados como C7 (Via Principal), e C9 (Estacionamento Pavimentado), que teve 09,10% de suas amostras erroneamente classificadas como C10 (Edifício Residencial).

As dificuldades em separar essas classes de cobertura e pavimentação se justificam pela semelhança em suas assinaturas espetrais, ou seja, são constituídas pelos mesmos materiais, como o concreto, por exemplo. Durán et al. (2018) reforçam que o cimento e o concreto são os materiais mais comuns no meio urbano, sendo utilizados para calçadas de pedestres e estacionamentos de veículos, na forma de blocos pré-moldados ou em superfície lisa, bem como para a cobertura de edifícios e telhas. Espera-se, então, que essas classes possam ser diferenciadas pelo uso de imagens hiperespectrais, destinadas a discriminar seus materiais de composição, associadas ao uso de dados do sensor Optech Titan MW, projetado para diferenciar classes em alturas distintas.

Figura 4 – Classificação com *Dataset 1*.

Elaboração: Os autores (2025).

4.2 Resultados do *Dataset 2*

Conforme explicado anteriormente, o *Dataset 2* compreende a cena do ITRES CASI 1500 e os respectivos componentes MNF e PCA. Desta forma, foram empregadas 48 bandas originais deste sensor, 13 MNF e 6 PCA, o que resultou em 67 camadas de entrada. O resultado da classificação do *Dataset 2* é mostrado na Figura 6.

A classificação do *Dataset 2* com o algoritmo RF obteve 60,99% de exatidão global. A classe com o melhor percentual de acerto na classificação foi a C9 (Estacionamento Pavimentado), 95,45%. Algumas classes, no entanto, apresentaram confusões, como a classe C7 (Via Principal), que teve 16,87% de suas amostras classificadas erroneamente como C11 (Estrada) e 11,04% como C12 (Calçada). Este problema era de certa forma esperado, uma vez que os materiais possuem a mesma constituição estrutural e condições de superfície. Além disso, também foram relatadas confusões em que a classe C11 (Estrada) apresentou 13,75% dos casos classificados erroneamente como C10 (Edifício Residencial) e 14,81% como C7 (Via Principal), e o caso da classe C8 (Edifício Não Residencial), que teve 18,93% de suas amostras classificadas erroneamente como C10 (Edifício Residencial).

As confusões ocorridas com as classes de cobertura e pavimentação são aceitáveis devido à semelhança espectral, conforme mencionado anteriormente. Para classificá-las corretamente, o uso de informações de altura derivadas da cena do sensor Optech Titan MW é crucial (Stewart & Oke, 2012). O aspecto positivo da classificação resultante do *Dataset 2* é a redução da confusão entre algumas classes, como C1 (Grama Artificial) e C6 (Grama Saudável). Tal melhoria demonstra o potencial dos dados hiperespectrais para uma discriminação refinada de alvos em um ambiente urbano.

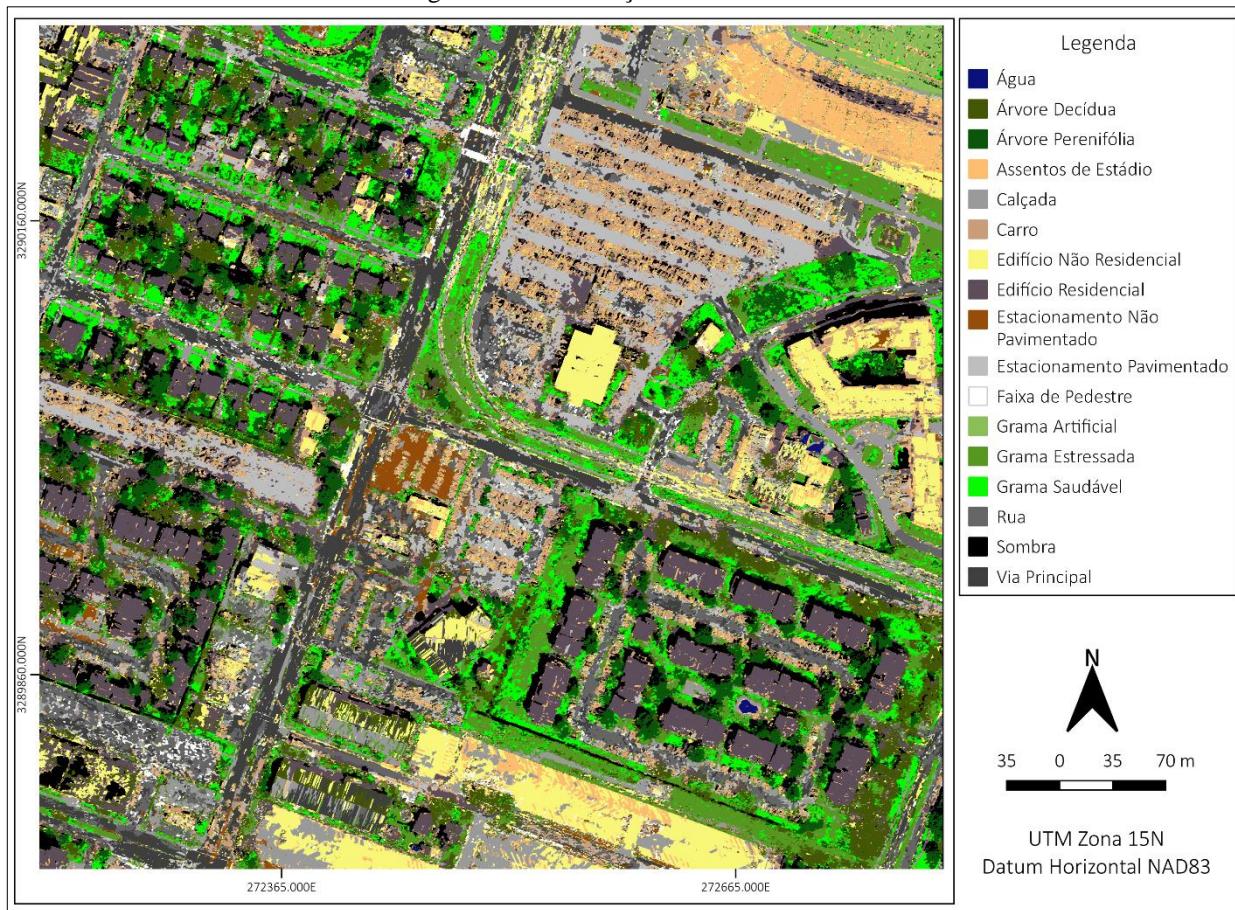
Figura 5 – Classificação com *Dataset 2*.

Elaboração: Os autores (2025).

4.3 Resultados do *Dataset 3*

O resultado referente à classificação do *Dataset 3* usando a cena Optech Titan MW é apresentado na Figura 7. Foram 3 camadas de modelo digital de elevação, 1 camada de modelo digital de superfície e 3 bandas de imagem de intensidade LiDAR em diferentes comprimentos de onda (G, NIR, SWIR), resultando em 7 camadas de entrada. A classificação do *Dataset 3* com o algoritmo de RF alcançou 45,71% de exatidão global. Este *dataset* compreendeu a maior ocorrência de confusão entre classes.

A classe C7 (Via Principal) teve 26,80% dos casos classificados erroneamente como C11 (Estrada); C9 (Estacionamento Pavimentado) apresentou 49,12% de ocorrências classificadas erroneamente como C11 (Estrada), e C11 (Estrada) teve 22,95% de suas amostras confundidas com C7 (Via Principal). É claramente perceptível que essas imprecisões são justificadas pela semelhança de altura. De acordo com Xu et al. (2019) e Rasti et al. (2020), a vantagem do uso de dados LiDAR para classificação urbana é justamente a discriminação de materiais de superfície caracterizados por diferentes alturas. Apesar dessas confusões e dos baixos percentuais de acertos, algumas classes da classificação RF, mesmo com pequena diferença de altura, apresentaram resultados marcantes, como a distinção entre as classes C12 (Calçada) e C11 (Estrada) com apenas 1,92% de confusão. Além disso, C3 (Faixa de Pedestre) e C13 (Assentos de Estádio) foram totalmente diferenciados entre si (0%).

Figura 6 - Classificação com *Dataset 3*.

Elaboração: Os autores (2025).

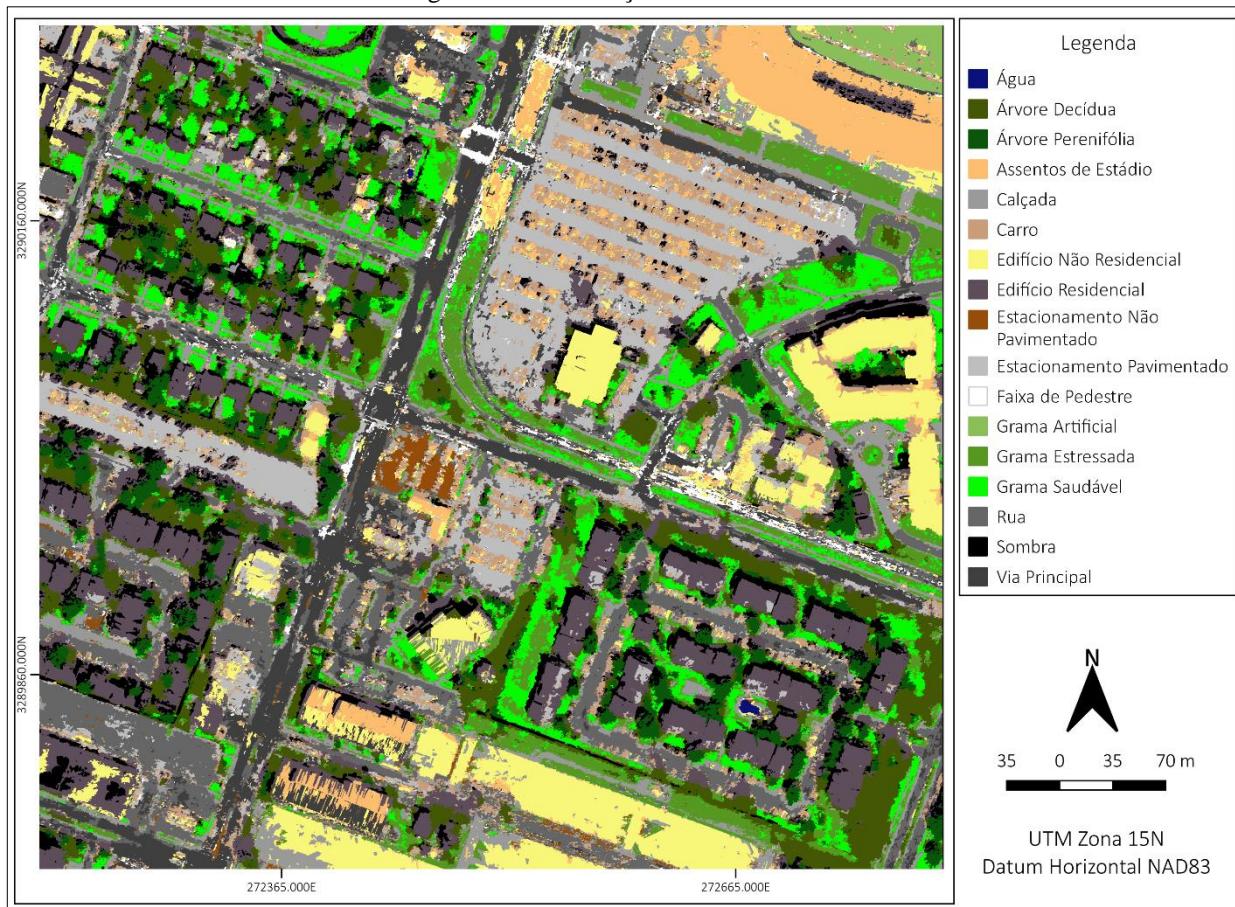
4.4 Resultados do *Dataset 4* (*Datasets 1 e 2*)

O resultado da classificação do *Dataset 4*, baseado no conjunto das cenas DiMAC ULTRALIGHT+ e ITRES CASI 1500 é apresentado na Figura 8. Os valores a serem apresentados correspondem respectivamente aos dois sensores utilizados em questão. Desta forma, foram empregadas, respectivamente, 3 e 48 bandas originais dos sensores. Dentre as componentes, foram respectivamente utilizadas 3 e 13 bandas de MNF, 3 e 6 bandas de PCA, resultando, portanto, em 76 camadas de entrada.

A classificação deste *dataset* resultou em uma exatidão global de 65,39%. As classes com os melhores percentuais de acerto foram C16 (Água), C9 (Estacionamento Pavimentado) e C15 (Estacionamento Não Pavimentado), atingindo, nessa ordem, 100%, 96,61% e 93,65%. Entretanto, algumas classes apresentaram confusões, que de certa forma eram esperadas, como, por exemplo, a classe C8 (Edifício Não Residencial), que apresentou 20,05% dos casos erroneamente classificados como C10 (Edifício Residencial); e a classe C11 (Estrada), tendo sido 16,87% das amostras classificadas como C7 (Via Principal) e 12% como C9 (Estacionamento Pavimentado). Estes resultados não são surpreendentes, como citado anteriormente, devido a suas semelhanças espectrais.

O mesmo é observado em relação à confusão existente na classe C7 (Via Principal), com 16,22% das ocorrências erroneamente classificadas como C11 (Estrada). Outro resultado interessante é a classificação de C4 (Árvore Caducifólia) como C14 (Gramá Estressada), totalizando 11,36%. Tal confusão respalda-se no aspecto de ambas, já que se apresentam de forma seca e sem vida. Freire (2016) demonstra tais características, submetendo uma espécie de vegetação a variados processos de adaptação e estresse. Outro destaque diz respeito à falta de um sensor de elevação para distinguir as variações dos alvos.

Apesar dessas variações, é significativa a mudança nos resultados quando comparados aos conjuntos individuais. Em todo caso, é necessário conduzirem-se os testes de hipótese, a fim de se confirmar tais evidências.

Figura 7 - Classificação com *Dataset 4*.

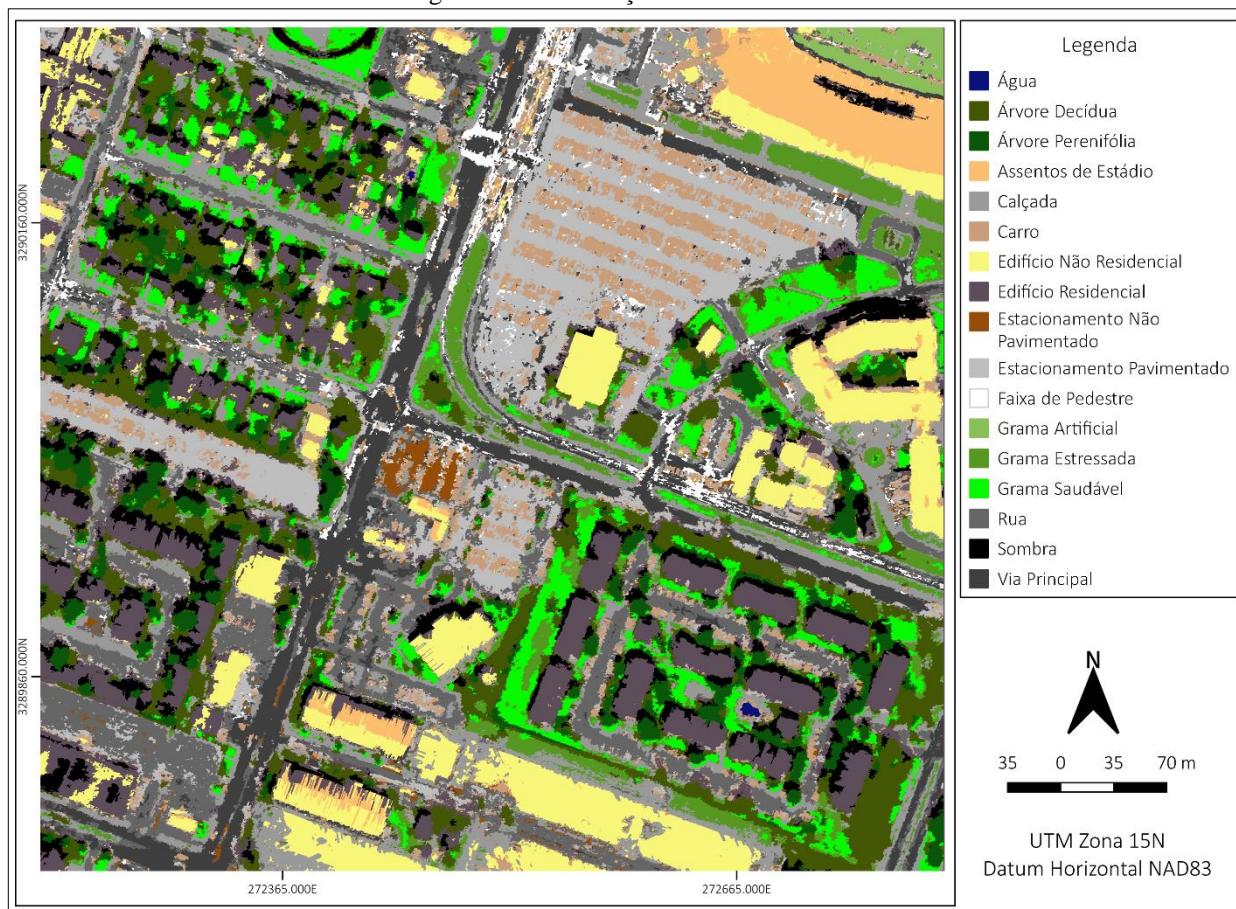
Elaboração: Os autores (2025).

4.5 Resultados do *Dataset 5* (*Datasets 2 e 3*)

O resultado referente à classificação do *Dataset 5* usando o conjunto das cenas ITRES CASI 1500 e Optech Titan MW é apresentado na Figura 9. Para este conjunto, foram utilizadas 74 camadas de entrada, das quais 48 bandas originais do sensor hiperespectral, além de 13 e 6 componentes MNF e PCA, respectivamente. Ademais, foram empregadas 3 camadas de modelo digital de elevação, 1 camada de modelo digital de superfície e 3 bandas de imagem de intensidade LiDAR em diferentes comprimentos de onda (G, NIR, SWIR). A classificação do *Dataset 5* com o algoritmo RF alcançou 72,70% de exatidão global, o que claramente indica uma melhoria significativa de resultados quando comparados com os demais conjuntos apresentados.

Apesar deste importante resultado, algumas classes apresentaram confusões, como: C11 (Estrada) classificada erroneamente como C7 (Via Principal) e 12,10% como C9 (Estacionamento Pavimentado). Tais resultados já eram esperados, pois apesar da presença dos sensores para determinar tais diferenças, as composições materiais são as mesmas.

Outro resultado interessante, porém não aguardado, é a confusão obtida entre as classes C6 (Gramá Saudável) e C14 (Gramá Estressada), com 27,78% de erro na classificação. Embora o sensor hiperespectral tenha a capacidade de caracterizar com precisão a composição química de vários materiais, houve falta de resolução espacial, já que esta determina as relações geométricas dos pixels da imagem (entre si), propiciando, portanto, a extração de informações adicionais.

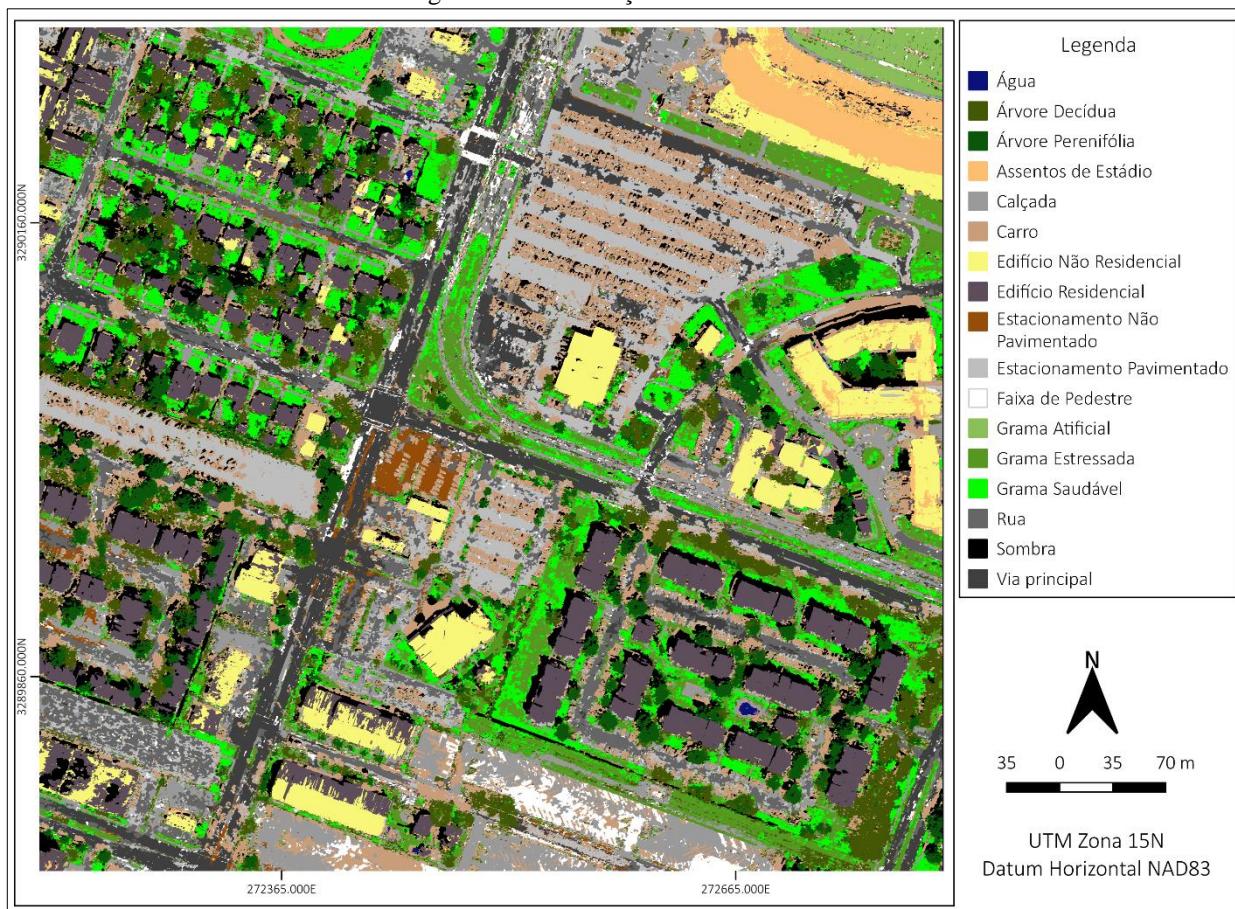
Figura 8 - Classificação com *Dataset 5*.

Elaboração: Os autores (2025).

4.6 Resultados do *Dataset 6* (*Datasets 1 e 3*)

Conforme explicado anteriormente (Tabela 3), o *Dataset 6* compreende as cenas DiMAC ULTRALIGHT+ e Optech Titan MW, portanto, foram trabalhadas 16 camadas de entrada, das quais 3 são bandas originais da câmera multiespectral, 3 componentes MNF e 3 PCA, e da outra cena, 3 camadas de modelo digital de elevação, 1 camada de modelo digital de superfície e 3 bandas de imagem de intensidade LiDAR em diferentes comprimentos de onda (G, NIR, SWIR). Este conjunto alcançou 67,48% de exatidão global.

Em comparação com os últimos resultados, é visível em termos de porcentagem da exatidão global uma queda nos resultados. Entretanto, deve-se considerar a diferença de camadas de entrada empregadas. Consequentemente, este grupo apresentou algumas confusões, como C14 (Gramá Estressada) com C6 (Gramá Saudável), em que 22,58% foi erroneamente classificado. Este resultado é consequência direta do menor número de bandas da câmera multiespectral. Outros resultados, como as confusões entre materiais de mesma composição, são também apresentados neste *dataset*, como, por exemplo, C3 (Faixa de Pedestre) classificada em 28% como C7 (Via Principal); e C11 (Estrada) erroneamente classificada em 19,58% como C7 (Via Principal).

Figura 9 - Classificação com *Dataset 6*.

Elaboração: Os autores (2025).

4.7 Resultados do *Dataset 7* (*Datasets 1, 2 e 3*)

O resultado referente à classificação do *Dataset 7* é mostrado na Figura 11. Este *dataset* é a combinação dos três conjuntos de dados apresentados anteriormente, sendo 9 camadas do *Dataset 1*, 67 camadas do *Dataset 2* e 7 camadas do *Dataset 3*, resultando em 83 camadas de entrada (Tabela 3).

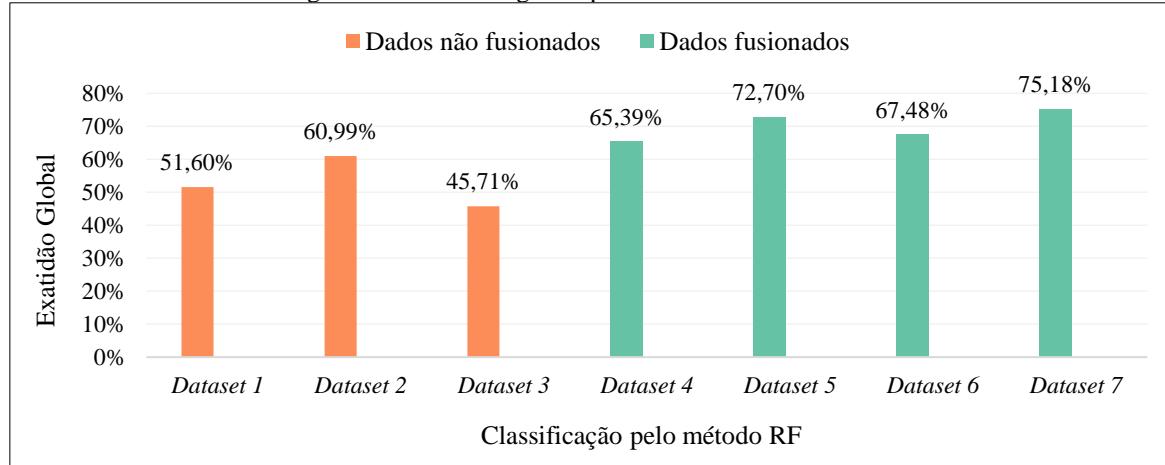
A classificação do *Dataset 7* com o algoritmo RF atingiu 75,18% de exatidão global. As classes C1 (Grama Artificial), C9 (Estacionamento Pavimentado), C15 (Estacionamento Não Pavimentado) e C16 (Água) apresentaram 100,0% de acerto. Todas as demais classes resultaram em valores de acerto superiores a 50,0% e com redução da confusão. Esse *dataset* atendeu às expectativas, pois apresentou a melhor exatidão global em comparação com os outros conjuntos de dados. No entanto, destaca-se que C7 (Via Principal) teve 15,59% de suas amostras classificadas erroneamente como C11 (Estrada). Tal confusão é aceitável, pois essas classes possuem características semelhantes, já que são feitas do mesmo material e têm a mesma altura, dificultando consideravelmente sua discriminação.

Figura 10 - Classificação com *Dataset 7*.

Elaboração: Os autores (2025).

4.8 Comparativos de exatidão global, erros de comissão e omissão e teste de hipótese

A Figura 11 ilustra a comparação entre as classificações e reforça a eficiência do conjunto da fusão de dados.

Figura 11 – Exatidão global para todos os *datasets*.

Dataset 1 é composto por 9 camadas, sendo 3 do sensor DiMAC ULTRALiGHT+, 3 MNF e 3 PCA. *Dataset 2* possui 67 camadas, sendo 48 da Cena ITRES CASI 1500, 13 MNF e 6 PCA. *Dataset 3* é formado por 7 camadas LiDAR. *Datasets 4, 5, 6 e 7* são dados fusionados, sendo respectivamente a junção dos *Datasets 1 e 2; 2 e 3; 1 e 3; e 1, 2 e 3*.

Elaboração: Os autores (2025).

Além dessa comparação, as Tabelas S1 a S4 apresentam os valores para acurácia do produtor por classe, acurácia do usuário da classe, erro de comissão por classe e erro de omissão por classe. Esses valores reforçam os resultados já apresentados para a classificação RF. Tais tabelas estão ilustradas no Apêndice.

Três testes de hipótese Z com 5% de nível de significância foram realizados. O objetivo é analisar comparativamente as classificações, verificando-se se os valores de exatidão global e índice Kappa comparados são ou não significativamente diferentes. As hipóteses testadas e os resultados são apresentados resumidamente na Tabela 7 para os conjuntos de dados não fusionados, e na Tabela 8 para os conjuntos de dados fusionados.

Tabela 7 – Valores resultantes do teste de hipótese Z para os *Datasets* 1 a 3.

<i>Dataset</i> 1	H_0 : Kappa1 = 0	<i>Dataset</i> 2	H_0 : Kappa2 = 0	<i>Dataset</i> 3	H_0 : Kappa3 = 0
	H_1 : Kappa1 > 0		H_1 : Kappa2 > 0		H_1 : Kappa3 > 0
	Z = 4,78		Z = 8,63		Z = 3,90
	Valor-P = 0,0000		Valor-P = 0,0000		Valor-P = 0,0000
	Alfa = 0,05		Alfa = 0,05		Alfa = 0,05
	Kappa = 0,4665		Kappa = 0,5574		Kappa = 0,3956
Conclusão	rejeito H_0 , o Kappa1 é significativamente superior a zero.	Conclusão	rejeito H_0 , o Kappa 2 é significativamente superior a zero.	Conclusão	rejeito H_0 , o Kappa 3 é significativamente superior a zero.

H_0 : hipótese nula; H_1 : hipótese alternativa; Z: estatística do teste de hipótese Z com distribuição normal; Valor-P: probabilidade de se observar uma diferença tão grande ou maior do que aquela observada sob a hipótese nula; Alfa: nível de significância correspondente a 1 – IC, em que IC é o intervalo de confiança.

Elaboração: Os autores (2025).

Tabela 8 - Valores resultantes do teste de hipótese Z para os *Datasets* 4 a 7.

<i>Dataset</i> 4	H_0 : Kappa4 = 0	<i>Dataset</i> 5	H_0 : Kappa5 = 0	<i>Dataset</i> 6	H_0 : Kappa6 = 0	<i>Dataset</i> 7	H_0 : Kappa7 = 0
	H_1 : Kappa4 > 0		H_1 : Kappa5 > 0		H_1 : Kappa6 > 0		H_1 : Kappa7 > 0
	Z = 11,74		Z = 20,34		Z = 10,79		Z = 24,97
	Valor-P = 0,0000						
	Alfa = 0,05						
	Kappa = 0,6121		Kappa = 0,6941		Kappa = 0,6393		Kappa = 0,7231
Conclusão	rejeito H_0 , o Kappa 4 é significativamente superior a zero.	Conclusão	rejeito H_0 , o Kappa 5 é significativamente superior a zero.	Conclusão	rejeito H_0 , o Kappa 6 é significativamente superior a zero.	Conclusão	rejeito H_0 , o Kappa 7 é significativamente superior a zero.

H_0 : hipótese nula; H_1 : hipótese alternativa; Z: estatística do teste de hipótese Z com distribuição normal; Valor-P: probabilidade de se observar uma diferença tão grande ou maior do que aquela observada sob a hipótese nula; Alfa: nível de significância correspondente a 1 – IC, em que IC é o intervalo de confiança.

Elaboração: Os autores (2025).

Um sumário comparativo dos resultados dos testes para os conjuntos fusionados é apresentado na sequência:

- Teste 1 - Comparação entre os *Datasets* 4 e 7.
 - Resultado: o índice Kappa do *Dataset* 4 (0,6121) é significativamente menor que o índice Kappa do *Dataset* 7 (0,7231).
- Teste 2 - Comparação entre os *Datasets* 5 e 7.
 - Resultado: o índice Kappa do *Dataset* 5 (0,6941) é significativamente menor que o índice Kappa do *Dataset* 7 (0,7231).
- Teste 3 - Comparação entre os *Datasets* 6 e 7.
 - Resultado: o índice Kappa do *Dataset* 6 (0,6393) é significativamente menor que o índice Kappa do *Dataset* 7 (0,7231).

A validação dos dados foi feita com diversos indicadores da qualidade das classificações, mas somente o teste de hipótese pode afirmar se o índice Kappa de uma classificação é significativamente superior ao de outra. De acordo com estes testes de hipótese e comparando-se o desempenho dos distintos *datasets*, constata-se que o método de fusão de dados é significativamente superior aos demais.

5 CONCLUSÃO

Foram realizadas sete diferentes classificações visando detalhar a cobertura do solo urbano. Para isso, foram utilizadas imagens com alta resolução espacial e espectral e dados de elevação. Esses dados compreendem, respectivamente, cenas dos sensores DiMAC ULTRALIGHT+, ITRES CASI 1500 e Optech Titan MW fornecidos pelo NCALM e HIALab da Universidade de Houston por meio de um concurso realizado anualmente pelo GRSS–IEEE (*Data Fusion Contest*).

Este conjunto de dados original foi subdividido em sete novos conjuntos de dados diferentes, caracterizados pelos dados multiespectrais de resolução espacial muito alta, os dados hiperespectrais, os dados de elevação, conjuntos pareados e a fusão de dados. O mesmo conjunto de amostras aleatórias foi adotado para os sete diferentes conjuntos de dados para fins de padronização do treinamento. A coleta das amostras de treinamento foi precedida por uma etapa de extração de características, uma vez que foram utilizadas não apenas as bandas dos sensores originais, mas também os componentes MNF e PCA no caso dos sensores passivos. Além disso, foram utilizados atributos customizados e índices espetrais, como os de vegetação.

As classificações foram geradas usando o classificador RF. Sete matrizes de confusão baseadas em conjuntos de validação independentes foram geradas, e seus índices de acurácia calculados. Os resultados gerados para os conjuntos de dados (*Datasets*) 1, 2, 3, 4, 5 e 6 apresentaram algumas tendências de acertos e erros, todos eles com confusão significativa e acurácia limitada em comparação com o conjunto de fusão total de dados.

O conjunto de dados 1 (*Dataset 1*), por exemplo, apresentou baixa exatidão global (51,60%), dada a similaridade dos alvos na região espectral do visível. O conjunto de dados 2 (*Dataset 2*) reduziu um pouco a confusão entre as classes mais semelhantes, mas não conseguiu distinguir materiais semelhantes com alturas diferentes. O conjunto de dados 3 (*Dataset 3*), por sua vez, abordou com mais acurácia a diferença de altura dos alvos, embora não contivesse informações espetrais suficientes para atingir uma elevada exatidão. O conjunto de dados 7 (*Dataset 7*), diferentemente dos anteriores, foi capaz de discriminar os alvos de interesse no ambiente urbano, atingindo 75,18% de exatidão global, valor próximo ao reportado na literatura.

Com o objetivo de analisar a similaridade entre as classificações, foram realizados os testes de hipótese. O teste de similaridade Z demonstrou que, em 100% dos casos, o conjunto de dados em que foi empregada a fusão total apresentou superioridade de desempenho.

Portanto, o uso combinado de dados de múltiplos sensores (RGB, HSI e LiDAR) melhorou substancialmente os resultados da classificação. Desta maneira, este trabalho demonstrou as possibilidades promissoras de combinar informações de vários sensores para uma caracterização acurada de alvos em um ambiente urbano. Como diretrizes para trabalhos futuros, pretende-se enriquecer a etapa de extração de características, adicionando índices espetrais personalizados existentes e novos, bem como métricas de textura especificamente relatadas na literatura como adequadas para detecção de alvos urbanos. Além disso, deve-se reconhecer que é necessário avaliar outros classificadores, como CNN, devido aos refinamentos desta abordagem, de modo a explorar todo o seu potencial para realizar classificações de cobertura do solo urbano com um nível de legenda detalhada e atingir ao mesmo tempo índices de acurácia elevados.

Agradecimentos

Ao Programa de Pós-Graduação em Ciências Geodésicas da Universidade Federal do Paraná (PPGCG/UFPR); À Fundação Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), Código 001 (P.C.M). Este estudo foi financiado pela Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), Processo n.º 2020/09215-3 (C.M.A.), e pelo Conselho Nacional de Desenvolvimento Científico e Tecnológico, Processo n.º 311324/2021-5 (C.M.A.). A *Geoscience and Remote Sensing Society – Institute of Electrical and Electronics Engineers* (GRSS–IEEE), pelas imagens utilizadas neste trabalho.

Contribuição dos Autores

A primeira autora contribuiu na conceptualização, curadoria dos dados, análise formal, investigação,

metodologia, software, validação, visualização e redação – minuta inicial. A segunda autora contribuiu na conceptualização, curadoria dos dados, metodologia, administração do projeto, recursos, supervisão, validação, visualização e redação – revisão e edição. A terceira autora contribuiu com a conceptualização, metodologia, visualização e redação – revisão e edição. O quarto autor contribuiu com a redação – revisão, e supervisão.

Conflitos de Interesse

Os autores declaram que não há conflitos de interesse.

Referências

- Ali, A., Martelli, R., Lupia, F., & Barbanti, L. (2019). Assessing Multiple Years' Spatial Variability of Crop Yields Using Satellite Vegetation Indices. *Remote Sensing*, 11 (20), 2384–2406. <https://doi.org/10.3390/rs11202384>.
- Anjos, C. S., Almeida, C. M., & Galvão, L. S (2017a). *Classificação por árvores de decisão: Avaliação de acurácia com e sem a pré-seleção de atributos*. In: Simpósio Brasileiro de Sensoriamento Remoto, Santos. <http://marte2.sid.inpe.br/col/sid.inpe.br/marte2/2017/10.27.15.47/doc/thisInformationItemHomePage.html>.
- Anjos, C. S., Almeida, C. M., Galvão, L. S., Souza-Filho, C. R., Lacerda, M.G., & Prati, R.C. (2017b). Analysis of the level of detail in classifications of urban areas with optical VHR and hyperspectral images using C4.5 decision tree and random forest methods. *Bulletin of Geodetic Sciences*, 2 (23), 371–388. <https://dx.doi.org/10.1590/S1982-21702017000200024>.
- Anjos, C. S., Lacerda, M. G., Andrade, L., Salles R. N., & Almeida, C. M. (2019). *Fusão de Dados: Nova Tendência em Processamento Digital de Imagens*. In: Simpósio Brasileiro De Sensoriamento Remoto, Santos. <https://proceedings.science/sbsr-2019/trabalhos/fusao-de-dados-nova-tendencia-em-processamento-digital-de-imagens?lang=pt-br>.
- Anjos, C. S. (2016) *Classificação de áreas urbanas com imagens multiespectrais e hiperespectrais utilizando métodos não paramétricos*. [Tese de doutorado, Instituto Nacional de Pesquisas Espaciais]. Repositório digital de teses e dissertações INPE. <http://mtc-m21b.sid.inpe.br/col/sid.inpe.br/mtc-m21b/2016/04.04.19.03/doc/publicacao.pdf>.
- Baatz, M., & Schäpe, A. (2000). Multiresolution Segmentation—an optimization approach for high quality multi-scale image segmentation. *Angewandte Geographische Informations-Verarbeitung XII*. 12, 12–23. <https://www.semanticscholar.org/paper/Multiresolution-Segmentation-%3A-an-optimization-for-Baatz-Sch%C3%A4pe/364cc1ff514a2e11d21a101dc072575e5487d17e>.
- Blaschke, T. (2010). Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65 (1), 2–16. <https://doi.org/10.1016/j.isprsjprs.2009.06.004>.
- Congalton, R. G. (1988). A comparison of sampling schemes used in generating error matrices for assessing the accuracy of maps generated from remotely sensed data. *Photogrammetric Engineering and Remote Sensing*, 54 (5), 593–600. https://www.asprs.org/wp-content/uploads/pers/1988journal/may/1988_may_593-600.pdf.
- Congalton, R. G. & Green, K. (2009). *Assessing the accuracy of remotely sensed data: principles and practices*. Boca Raton. <https://doi.org/10.1201/9781420055139>.
- Costa, J.D.S., Liesenberg, V., Schimalski, M.B., Sousa, R.V.D., Biffi, L.J., Gomes, A.R., Neto, S.L.R., Mitishita, E., & Bispo, P.D.C. (2021). Benefits of Combining ALOS/PALSAR-2 and Sentinel-2A Data in the Classification of Land Cover Classes in the Santa Catarina Southern Plateau. *Remote Sensing*, 13 (2), 229–261. <https://doi.org/10.3390/rs13020229>.
- Definiens. *Definiens Documentation: Developer XD 2.0.4.* (2012) Definiens AG. <https://www.imperial.ac.uk/media/imperial-college/medicine/facilities/film/Definiens-Developer->

Reference-Book-XD-2.0.4.pdf.

- Durán, G., Filho, W. P., & Kuplich, T. M. (2018). Identificação espectral de materiais urbanos com a técnica mapeador de ângulo espectral (SAM) e o sensor de alta resolução espacial Geogeye-1. *Geographic Bulletin of Rio Grande do Sul*, (31), 9–34. <https://revistas.planejamento.rs.gov.br/index.php/boletim-geografico-rs/article/view/4011>.
- Fan, Y., Ni, D., & Ma, H. (2017). HyperDB: A Hyperspectral Land Class Database Designed for an Image Processing System. *IEEE Tsinghua Science and Technology*, 22 (1), 112–118. <https://doi.org/10.1109/TST.2017.7830901>.
- Fernandez-Diaz, J.C., Carter, W.E., Glennie, C., Shrestha, R.L., Pan, Z., Ekhtari, N., Singhania, A., Hauser, D., & Sartori, M. (2016). Capability Assessment and Performance Metrics for the Titan Multispectral Mapping Lidar. *Remote Sensing*, 8 (11), 936–968. <https://doi.org/10.3390/rs8110936>.
- Freire, F. C. J. (2016). *Características fisiológicas de mudas de craibeira sob condições de deficiência hídrica*. [Dissertação de Mestrado, Universidade Federal de Alagoas]. Repositório digital de teses e dissertações UFAL. <https://www.repositorio.ufal.br/bitstream/riufal/1340/1/Caracter%C3%ADsticas%20fisiol%C3%B3gicas%20de%20mudas%20de%20craibeira%20sob%20condi%C3%A7%C3%A7%C3%95es%20de%20defici%C3%A7%C3%A1ncia%20h%C3%A3drica.pdf>.
- Gao, D., Hu, Z., & Ye, R. (2018). Self-Dictionary Regression for Hyperspectral Image Super-Resolution. *Remote Sensing*, 10 (10), 1574–1596. <https://doi.org/10.3390/rs10101574>.
- Ghamisi, P., Höfle, B., & Zhu, X.X. (2017). Hyperspectral and LiDAR Data Fusion Using Extinction Profiles and Deep Convolutional Neural Network. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10 (6), 3011–3024. <https://doi.org/10.1109/JSTARS.2016.2634863>.
- Gitelson, A.A., Kaufman, Y.J., & Merzlyak, M.N. (1996). Use of a green channel in remote sensing of global vegetation from EOS-MODIS. *Remote Sensing Environment*, 58 (3), 289–298. [https://doi.org/10.1016/S0034-4257\(96\)00072-7](https://doi.org/10.1016/S0034-4257(96)00072-7).
- Green, A. A., Berman, M., Switzer, P., & Craig, M. D. (1988). A transformation for ordering multispectral data in terms of image quality with implications for noise removal, *IEEE Transactions on Geoscience and Remote Sensing*, 26 (1), 65–74, 1988. <https://ieeexplore.ieee.org/document/3001>.
- Happ, N. P., Ferreira, R. S., Bentes, C., Costa, G. A. O. P., & Feitosa, R. Q. (2009). *Segmentação multiresolução: uma abordagem paralela para segmentação de imagens de alta resolução em arquiteturas de múltiplos núcleos*. In: Proceedings of the XIV Brazilian Symposium of Remote Sensing, Natal. <http://marte.sid.inpe.br/col/dpi.inpe.br/sbsr@80/2008/11.18.01.10.13/doc/6935-6942.pdf>.
- Hu, L., Robinson, C. & Dilkina, B. (2021). *Model Generalization in Deep Learning Applications for Land Cover Mapping*. In: Fragile Earth'21: KDD 2021 Workshop, New York. <https://doi.org/10.48550/arXiv.2008.10351>.
- Huang, S., Tang, L., Hupy, J.P., Wang, Y., & Shao, G (2021). A commentary review on the use of normalized difference vegetation index (NDVI) in the era of popular remote sensing. *Journal of Forestry Research*, 32 (1), 1–6. <https://doi.org/10.1007/s11676-020-01155-1>.
- Jensen, J.R., & Cowen, D.C. (1999). *Remote Sensing of Urban/Suburban Infrastructure and Socio-Economic Attributes*. In: The Map Reader: Theories of Mapping Practice and Cartographic Representation, Oxford, United Kingdom. https://www.asprs.org/wp-content/uploads/pers/99journal/may/1999_may_611-622.pdf.
- Instituto Brasileiro de Geografia e Estatística (IBGE). (2017). *Classificação e caracterização dos espaços rurais e urbanos do Brasil: uma primeira aproximação*. IBGE. <https://biblioteca.ibge.gov.br/visualizacao/livros/liv100643.pdf>.
- Kuchler, P. (2021). *Utilização do sensoriamento remoto para o mapeamento dos sistemas integrados de produção agrícola: contribuição ao monitoramento da agricultura de baixa emissão de carbono no estado do Mato Grosso, Brasil*. [Tese de doutorado, Universidade do Estado do Rio de Janeiro]. Repositório

- digital de teses e dissertações UERJ. <http://www.alice.cnptia.embrapa.br/alice/handle/doc/1135585>.
- Kuras, A., Brell, M., Rizzi, J., & Burud, I. (2021). Hyperspectral and Lidar Data Applied to the Urban Land Cover Machine Learning and Neural-Network-Based Classification: A Review. *Remote Sensing*, 13 (17), 3393–3432. <https://doi.org/10.3390/rs13173393>.
- Lacerda, M.G. (2020). *Abordagem GEOBIA para Imagens VHR Obtidas por Aeronaves Remotamente Pilotadas e Sensores Satelitais com o Uso de Classificadores Individuais e Ensemble*. [Tese de doutorado, Instituto Tecnológico de Aeronáutica São José dos Campos]. Repositório digital de teses e dissertações ITA. https://www.researchgate.net/profile/Marielcio-Lacerda-2/publication/373514773_Abordagem_GEOBIA_para_imagens_VHR_obtidas_por_aeronaves_remotamente_pilotadas_e_sensores_satelitais_com_o_uso_de_classificadores_individuais_e_ensemble/links/64ef99c90f7ab20a8666f6d0/Abordagem-GEOBIA-para-imagens-VHR-obtidas-por-aeronaves-remotamente-pilotadas-e-sensores-satelitais-com-o-uso-de-classificadores-individuais-e-ensemble.pdf
- Leonardi, F. (2010). *Abordagens Cognitivas e Mineração de Dados Aplicadas a Dados Ópticos Orbitais e de Laser para a Classificação de Cobertura do Solo Urbano*. [Dissertação de mestrado, Instituto Nacional de Pesquisas Espaciais]. Repositório digital de teses e dissertações INPE. <http://mtc-m16d.sid.inpe.br/col/sid.inpe.br/mtc-m19@80/2010/03.17.11.42/doc/publicacao.pdf>.
- Li, J., Hong, D., Gao, L., Yao, J., Zhengda, K., Zhang, B., & Chanussot, J. (2022). Deep learning in multimodal remote sensing data fusion: A comprehensive review. *ELSEVIER International Journal of Applied Earth Observation and Geoinformation*, 112, 1–16. <https://doi.org/10.1016/j.jag.2022.102926>.
- Li, Z., Chen, B., Wu, S., Su, M., Chen, J. M., & Xu, B. (2024). Deep learning for urban land use category classification: A review and experimental assessment. *Remote Sensing of Environment*, 311 (114290). <https://doi.org/10.1016/j.rse.2024.114290>.
- Lillesand, T. M., Kiefer, R. W., & Chipman, J. W. (2015). *Remote sensing and image interpretation*. Wiley and Sons. <https://www.geokniga.org/bookfiles/geokniga-remote-sensing-and-image-interpretation.pdf>.
- Liu, S., Marinelli, D., Bruzzone, L., & Bovolo, F. (2019). A review of change detection in multitemporal hyperspectral images: Current techniques, applications, and challenges. *IEEE Geoscience and Remote Sensing Magazine*, 7 (2), 140–158. <https://doi.org/10.1109/MGRS.2019.2898520>.
- Lopes, T. D., Goedtel, A., Palacios, R.H. C., & Godoy, W. F. (2017). *Aplicação do Algoritmo Random Forest como Classificador de Padrões de Falhas em Rolamentos de Motores de Indução*. In: XIII Brazilian Symposium on Intelligent Automation, Porto Alegre. https://www.sba.org.br/Proceedings/SBAI/SBAI2017/SBAI17/papers/paper_98.pdf.
- Martins, R. C. (2017). *Definição de zonas de manejo por índice de vegetação obtidos por sensoriamento remoto e mapas de produtividade*. [Dissertação de mestrado, Universidade Federal de Santa Maria]. Repositório digital de teses e dissertações UFSM. <https://repositorio.ufsm.br/bitstream/handle/1/11346/Martins%20Raffael%20Chielle.pdf?sequence=1&isAllowed=y>.
- Matsuoka, J. V. (2007). *Investigação do processo de segmentação multiresolução utilizando o critério de ponderação de formas e cores aplicadas às imagens de áreas urbanas de alta resolução espacial do satélite Ikonos*. In: XIII Brazilian Symposium of Remote Sensing, Florianópolis. <http://marte.sid.inpe.br/col/dpi.inpe.br/sbsr@80/2006/11.15.11.19/doc/589-596.pdf>.
- Motohka, T.; Nasahara, K.N.; Oguma, H.; & Tsuchida, S. (2010). Applicability of Green-Red Vegetation Index for Remote Sensing of Vegetation Phenology. *Remote Sensing*, 2 (10), 2369–2387. <https://doi.org/10.3390/rs2102369>.
- Nistor, C., Vîrghileanu, M., Cârlan, I., Mihai, B.-A., Toma, L., & Olariu, B. (2021). Remote Sensing-Based Analysis of Urban Landscape Change in the City of Bucharest, Romania. *Remote Sensing*, 13 (12), 2323–2342. <https://doi.org/10.3390/rs13122323>.
- Ouma, Y. O., Keitsilea, A., Nkwaea, B., Odirilea, P. Moalafhib, D., Qi, J. (2023). Urban land-use classification using machine learning classifiers: comparative evaluation and post-classification multi-feature fusion approach. *European Journal Of Remote Sensing*, 56 (1), 2–21.

[https://doi.org/10.1080/22797254.2023.2173659.](https://doi.org/10.1080/22797254.2023.2173659)

- Pande, S.; Uzun, B.; Guiotte, F.; Corpetti, T.; Delerue, F.; Lefèvre, S. (2024). Plant detection from ultra high resolution remote sensing images: a semantic segmentation approach based on fuzzy loss. *Computer Vision and Pattern Recognition*, 1, 1–5. https://www.researchgate.net/publication/383700535_Plant_detection_from_ultra_high_resolution_remote_sensing_images_A_Semantic_Segmentation_approach_based_on_fuzzy_loss.
- Panosso, A. R. (2019). *Estatística e Bioestatística*. (2019). Faculdade de Ciências Agrárias e Veterinárias (FCAV) – UNESP. https://www.fcav.unesp.br/Home/departamentos/cienciasexatas/alanrodrigopanosso/apostila_bioestatistica_2019.pdf.
- Qiu, C., Mou, L., Schmitt, M., & Zhu, X. X. (2019). Local climate zone-based urban land cover classification from multi-seasonal Sentinel-2 images with a recurrent residual network. *ISPRS Journal of Photogrammetry and Remote Sensing*, 154, 151–162. <https://doi.org/10.1016/j.isprsjprs.2019.05.004>.
- Rasti, B., Ghamsi, P., & Gloaguen, R. (2020). *Fusion of Multispectral Lidar and Hyperspectral Imagery*. In: 2020 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), Waikoloa, United States of America. <https://doi.org/10.1109/IGARSS39084.2020.9323179>.
- Richardson, A.J., & Wiegand, C.L. (1977). Distinguishing vegetation from soil background information. *Photogrammetric Engineering & Remote Sensing*, 43 (12), 1541–1552. https://www.asprs.org/wp-content/uploads/pers/1977journal/dec/1977_dec_1541-1552.pdf.
- Rocha, B. O., Körting, T. S., & Namikawa, L. M. (2024). Processamento de Imagens dos Satélites Brasileiros CBERS-4 e CBERS-4A para Respostas Rápidas a Desastres. *Rev. Bras. Cartogr*, 76 (1), 1–17. <http://dx.doi.org/10.14393/rbcv76n0a-70194>.
- Rondeaux, G., STEVEN, M., BARET, F. (1996). Optimization of soil-adjusted vegetation indices. *Remote Sensing of Environment*, 55 (2), 95–107. [https://doi.org/10.1016/0034-4257\(95\)00186-7](https://doi.org/10.1016/0034-4257(95)00186-7).
- Rouse, J.W., Haas, R.H. Schell, J.A., & Deering, W.D. (1974). Monitoring vegetation systems in the Great Plains with ERTS. *NASA Spec*, 351, (1), 309–317. <https://ntrs.nasa.gov/api/citations/19740022614/downloads/19740022614.pdf>.
- Siddiqui, A., Chauhan, P., Kumar, V., Jain, G., Deshmukh, A. & Kumar, P.(2020). Characterization of urban materials in AVIRISNG data using a mixture tuned matched filtering (MTMF) approach. *Geocarto International*, 37 (1), 332–347. <https://doi.org/10.1080/10106049.2020.1720312>.
- Son, J.D., Niu, G., Yang, B.S., Hwang, D.H., & Kang, D.S.(2009). Development of smart sensors system for machine fault diagnosis. *Expert Systems with Applications*, 36 (9), 11981–11991. <https://doi.org/10.1016/j.eswa.2009.03.069>.
- Stewart, I. D. & Oke, T. R. (2012). Local climate zones for urban temperature studies. *Bulletin of the American Meteorological Society*, 93 (12), 154–196,. <https://doi.org/10.1175/BAMS-D-11-00019.1>.
- Tucker, C.J. (1979). Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing Environment*, 8 (2), 127–150. [https://doi.org/10.1016/0034-4257\(79\)90013-0](https://doi.org/10.1016/0034-4257(79)90013-0).
- United States Census Bureau (USCB). (2018). *Cartographic Boundary Files – Shapefile*. <https://www.census.gov/geographies/mapping-files/time-series/geo/carto-boundary-file.html>.
- Xu, Y., Du, B., Zhang, L., Cerra, D., Pato, M., Carmona, E., Prasad, S., Yokoya, N., Hänsch, R., & Le Saux, B. (2019). Advanced multi-sensor optical remote sensing for urban land use and land cover classification: Outcome of the 2018 IEEE GRSS Data Fusion Contest. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 12 (6), 1709–1724. <https://doi.org/10.1109/JSTARS.2019.2911113>.
- Yang, R., Luo, F., Ren, F., Huang,W., Li, Q., Du, K., & Yuan, D. (2022). Identifying UrbanWetlands through Remote Sensing Scene Classification Using Deep Learning: A Case Study of Shenzhen, China. *ISPRS International Journal of Geo-Information*, 11 (2), 131–148. <https://doi.org/10.3390/ijgi11020131>.
- Yang, X. (2011). *What is urban remote sensing?: Urban Remote Sensing: Monitoring, Synthesis, and Modeling in the Urban Environment*. John Wiley and Sons.

- Zhang, J. (2010). Multi-source remote sensing data fusion: status and trends. *International Journal of Image and Data Fusion*, 1 (1), 5–24. <https://doi.org/10.1080/19479830903561035>.
- Zhou, F., & Zhong, D. (2020). Kalman filter method for generating time-series synthetic Landsat images and their uncertainty from Landsat and MODIS observations. *Remote Sensing of Environment*, 239 (1), 111628–111653. <https://doi.org/10.1016/j.rse.2019.111628>.

Biografia do autor principal



Pâmela Carvalho Molina é natural de Lorena – São Paulo, nascida em 1995. Graduada em Engenharia de Agrimensura e Cartográfica pelo Instituto Federal do Sul de Minas Gerais - Campus Inconfidentes e mestrado em Ciências Geodésicas pelo Programa de Pós-Graduação em Ciências Geodésicas da Universidade Federal do Paraná (PPGCG/UFPR). Atualmente exerce o cargo de Pesquisadora na Divisão de Comando, Controle, Comunicação, Computação, Inteligência, Vigilância e Reconhecimento (EC4ISR) no Instituto de Estudos Avançados (IEAv) na cidade de São José dos Campos/SP.



Esta obra está licenciada com uma Licença [Creative Commons Atribuição 4.0 Internacional](#) – CC BY. Esta licença permite que outros distribuam, remixem, adaptem e criem a partir do seu trabalho, mesmo para fins comerciais, desde que lhe atribuam o devido crédito pela criação original.

APÊNDICE

Tabelas Suplementares

Tabela S1 - Acurácia do produtor por classe.

Classes	<i>Dataset 1</i>	<i>Dataset 2</i>	<i>Dataset 3</i>	<i>Dataset 4</i>	<i>Dataset 5</i>	<i>Dataset 6</i>	<i>Dataset 7</i>
C1	42,31%	60,00%	12,50%	72,41%	77,78%	62,50%	100,00%
C2	73,77%	45,61%	55,10%	68,00%	78,63%	86,21%	84,21%
C3	38,00%	58,33%	38,00%	70,37%	77,92%	70,00%	90,00%
C4	63,46%	89,66%	55,41%	62,50%	86,96%	85,48%	91,38%
C5	33,33%	93,33%	40,00%	92,86%	93,33%	100,00%	94,74%
C6	25,61%	90,91%	30,43%	86,67%	84,62%	82,05%	88,89%
C7	46,09%	47,55%	34,97%	53,38%	58,97%	56,37%	52,88%
C8	42,54%	50,16%	41,75%	50,42%	64,86%	62,04%	68,62%
C9	81,82%	95,45%	35,09%	96,61%	100,00%	85,92%	100,00%
C10	73,63%	79,11%	72,39%	80,81%	80,12%	83,79%	83,88%
C11	29,38%	47,62%	31,15%	48,00%	53,85%	37,50%	56,50%
C12	33,33%	56,76%	19,23%	54,76%	65,71%	50,88%	63,16%
C13	35,38%	75,64%	31,88%	73,00%	97,17%	81,25%	90,91%
C14	65,45%	65,96%	62,75%	67,44%	58,33%	68,82%	87,23%
C15	100,00%	62,16%	95,35%	93,65%	86,96%	98,04%	100,00%
C16	74,29%	78,26%	67,74%	100,00%	94,55%	76,47%	100,00%

Elaboração: Os autores (2025).

Tabela S2 - Acurácia do usuário por classe.

Classes	<i>Dataset 1</i>	<i>Dataset 2</i>	<i>Dataset 3</i>	<i>Dataset 4</i>	<i>Dataset 5</i>	<i>Dataset 6</i>	<i>Dataset 7</i>
C1	73,33%	100,00%	85,71%	100,00%	98,00%	100,00%	100,00%
C2	38,46%	29,55%	24,11%	32,08%	70,77%	35,21%	40,00%
C3	48,72%	32,56%	51,35%	71,70%	81,08%	50,72%	60,00%
C4	24,63%	41,27%	27,52%	63,95%	37,74%	59,55%	63,86%
C5	21,43%	53,85%	19,35%	48,15%	48,28%	54,17%	81,82%
C6	25,00%	38,46%	14,89%	30,95%	39,29%	45,07%	47,06%
C7	59,00%	76,35%	53,50%	70,54%	81,17%	69,41%	80,41%
C8	75,28%	88,83%	67,54%	92,35%	90,00%	92,63%	95,71%
C9	38,03%	45,00%	19,42%	42,22%	47,48%	38,36%	52,27%
C10	69,39%	68,49%	72,39%	69,15%	73,66%	76,11%	77,41%
C11	50,98%	55,90%	30,32%	58,33%	65,77%	85,71%	68,48%
C12	33,33%	22,34%	29,85%	30,26%	25,00%	49,15%	55,81%
C13	38,33%	56,19%	29,33%	68,87%	86,55%	78,31%	76,19%
C14	39,56%	72,09%	35,96%	50,88%	63,64%	62,14%	64,06%
C15	78,13%	82,14%	74,55%	92,19%	96,77%	80,65%	95,74%
C16	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%

Elaboração: Os autores (2025).

Tabela S3 - Erro de comissão por classe.

Classes	<i>Dataset 1</i>	<i>Dataset 2</i>	<i>Dataset 3</i>	<i>Dataset 4</i>	<i>Dataset 5</i>	<i>Dataset 6</i>	<i>Dataset 7</i>
C1	26,67%	0,00%	14,29%	0,00%	2,00%	0,00%	0,00%
C2	61,54%	70,45%	75,89%	67,92%	29,23%	64,79%	60,00%
C3	51,28%	67,44%	48,65%	28,30%	18,92%	49,28%	40,00%
C4	75,37%	58,73%	72,48%	36,05%	62,26%	40,45%	36,14%
C5	78,57%	46,15%	80,65%	51,85%	51,72%	45,83%	18,18%
C6	75,00%	61,54%	85,11%	69,05%	60,71%	54,93%	52,94%
C7	41,00%	23,65%	46,50%	29,46%	18,83%	30,59%	19,59%
C8	24,72%	11,17%	32,46%	7,65%	10,00%	7,37%	4,29%
C9	61,97%	55,00%	80,58%	57,78%	52,52%	61,64%	47,73%
C10	30,61%	31,51%	27,61%	30,85%	26,34%	23,89%	22,59%
C11	49,02%	44,10%	69,68%	41,67%	34,23%	14,29%	31,52%
C12	66,67%	77,66%	70,15%	69,74%	75,00%	50,85%	44,19%
C13	61,67%	43,81%	70,67%	31,13%	13,45%	21,69%	23,81%
C14	60,44%	27,91%	64,04%	49,12%	36,36%	37,86%	35,94%
C15	21,88%	17,86%	25,45%	7,81%	3,23%	19,35%	4,26%
C16	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%

Elaboração: Os autores (2025).

Tabela S4 - Erro de omissão por classe.

Classes	<i>Dataset 1</i>	<i>Dataset 2</i>	<i>Dataset 3</i>	<i>Dataset 4</i>	<i>Dataset 5</i>	<i>Dataset 6</i>	<i>Dataset 7</i>
C1	57,69%	40,00%	87,50%	27,59%	22,22%	37,50%	0,00%
C2	26,23%	54,39%	44,90%	32,00%	21,37%	13,79%	15,79%
C3	62,00%	41,67%	62,00%	29,63%	22,08%	30,00%	10,00%
C4	36,54%	10,34%	44,59%	37,50%	13,04%	14,52%	8,62%
C5	66,67%	6,67%	60,00%	7,14%	6,67%	0,00%	5,26%
C6	74,39%	9,09%	69,57%	13,33%	15,38%	17,95%	11,11%
C7	53,91%	52,45%	65,03%	46,62%	41,03%	43,63%	47,12%
C8	57,46%	49,84%	58,25%	49,58%	35,14%	37,96%	31,38%
C9	18,18%	4,55%	64,91%	3,39%	0,00%	14,08%	0,00%
C10	26,37%	20,89%	27,61%	19,19%	19,88%	16,21%	16,12%
C11	70,62%	52,38%	68,85%	52,00%	46,15%	62,50%	43,50%
C12	66,67%	43,24%	80,77%	45,24%	34,29%	49,12%	36,84%
C13	64,62%	24,36%	68,12%	27,00%	2,83%	18,75%	9,09%
C14	34,55%	34,04%	37,25%	32,56%	41,67%	31,18%	12,77%
C15	0,00%	37,84%	4,65%	6,35%	13,04%	1,96%	0,00%
C16	25,71%	21,74%	32,26%	0,00%	5,45%	23,53%	0,00%

Elaboração: Os autores (2025).