

LETÍCIA MAYUMI MATSUDA

**ANÁLISE DE ATRIBUTOS ESPECTRAIS E DE TEXTURA NA CLASSIFICAÇÃO
DE ESPÉCIES DE VEGETAÇÃO AQUÁTICA EMERSA POR TÉCNICA DE
APRENDIZADO DE MÁQUINA**



LETÍCIA MAYUMI MATSUDA

**ANÁLISE DE ATRIBUTOS ESPECTRAIS E DE TEXTURA NA CLASSIFICAÇÃO
DE ESPÉCIES DE VEGETAÇÃO AQUÁTICA EMERSA POR TÉCNICA DE
APRENDIZADO DE MÁQUINA**

Dissertação apresentada ao Programa de Pós-Graduação em Ciências Cartográficas, da Faculdade de Ciências e Tecnologia, Universidade Estadual Paulista “Júlio de Mesquita Filho” – UNESP, campus de Presidente Prudente, como parte dos requisitos para a obtenção do título de Mestre em Ciências Cartográficas.

Orientador: Prof. Dr. Nilton Nobuhiro Imai

Coorientador: Prof. Dr. Adilson Berveglieri

Presidente Prudente - SP

2023

M434a

Matsuda, Leticia Mayumi

Análise de atributos espectrais e de textura na classificação de espécies de vegetação aquática emersa por técnica de aprendizado de máquina / Leticia Mayumi Matsuda. -- Presidente Prudente, 2024
101 p. : il., tabs.

Dissertação (mestrado) - Universidade Estadual Paulista (Unesp),
Faculdade de Ciências e Tecnologia, Presidente Prudente

Orientador: Nilton Nobuhiro Imai

Coorientador: Adilson Berveglieri

1. Sensoriamento remoto. 2. Vegetação aquática emersa. 3.
Atributos de textura. 4. Object-based image analysis (OBIA). I. Título.

Sistema de geração automática de fichas catalográficas da Unesp. Biblioteca da Faculdade de Ciências e Tecnologia, Presidente Prudente. Dados fornecidos pelo autor(a).

Essa ficha não pode ser modificada.

IMPACTO¹ ESPERADO DESTA DISSERTAÇÃO

Neste estudo foi proposto um método para a identificação de espécies de vegetação aquática emersa, utilizando imagens de Sensoriamento Remoto de alta resolução, em reservatórios de água, os quais são empregados para diversos usos: geração de energia elétrica; abastecimento público; projetos de irrigação; controle de inundações, além de serem utilizados para atividades como navegação, pesca e recreação. A construção desses reservatórios causa alterações ambientais que, atrelado a outros fatores, propicia o crescimento descontrolado de vegetação aquática nesses ambientes, o que prejudica os usos múltiplos da água. Assim, identificar as espécies de vegetação aquática permite realizar o manejo correto de cada uma delas, contribuindo na tomada de decisão da gestão pública em prol do uso público de água de qualidade e do usufruto de um meio ambiente equilibrado.

POTENCIAL IMPACT OF THIS DISSERTATION

This study proposes a method to help identify species of emerged aquatic vegetation using Remote Sensing high resolution images in water reservoirs, which are used for a variety of purposes: power generation; public supply; irrigation projects; flood control, alongside some activities such as navigation, fishing, and recreation. The construction of these reservoirs causes environmental changes which, linked to other factors, leads to the uncontrolled growth of aquatic vegetation, which harms the multiple uses of water. Thus, identifying the species of aquatic vegetation makes it possible to correctly manage each one of them, contributing to public management decision-making in favor of the public use of quality water and the enjoyment of a balanced environment.

¹ Informação adicionada de acordo com a Portaria Unesp nº 117, de 21 de dezembro de 2022.

CERTIFICADO DE APROVAÇÃO

TÍTULO DA DISSERTAÇÃO: Análise de atributos espectrais e de textura na classificação de espécies de vegetação aquática emergsa por técnica de aprendizado de máquina

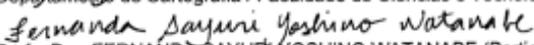
AUTORA: LETÍCIA MAYUMI MATSUDA

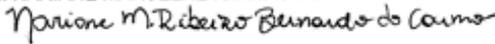
ORIENTADOR: NILTON NOBUHIRO IMAI

COORDENADOR: ADILSON BERVEGLIERI

Aprovada como parte das exigências para obtenção do Título de Mestra em Ciências Cartográficas, área: Aquisição, Análise e Representação de Informações Espaciais pela Comissão Examinadora:


Prof. Dr. NILTON NOBUHIRO IMAI (Participação Presencial)
Departamento de Cartografia / Faculdade de Ciências e Tecnologia de Presidente Prudente


Profa. Dra. FERNANDA SAYURI YOSHINO WATANABE (Participação Presencial)
Departamento de Cartografia / Faculdade de Ciências e Tecnologia de Presidente Prudente

Profa. Dra. NARIANE MARSELHE RIBEIRO BERNARDO DO CARMO (Participação Presencial)
Inspectral 

Presidente Prudente, 20 de abril de 2023

*À minha mãe, Regina,
por todo o amor, apoio e dedicação.*

AGRADECIMENTOS

Meus agradecimentos são todos igualmente importantes. Dou início agradecendo à Deus, por toda as bênçãos de graças, força e proteção recebidas.

À minha mãe, Regina, pelo amor incondicional, pelas orações, por todo o apoio e suporte, por ser meu porto seguro.

Aos meus orientadores, Prof. Dr. Nilton Nobuhiro Imai e Prof. Dr. Adilson Berveglieri, por serem exemplos de competência, dedicação e eficiência. Agradeço por toda a confiança, paciência, compreensão e incentivo.

À banca, Profa. Dra. Fernanda Watanabe e Profa. Dra. Nariane Bernardo, pelo tempo despendido neste trabalho e pelas valiosas contribuições, do exame de qualificação à defesa da dissertação.

Ao meu pai, Pedro, pelas palavras carinhosas que me tranquilizam e motivam em momentos desafiadores. Agradeço por todo o amor e torcida.

Ao meu padrasto, Nivaldo, pelo carinho, colaboração, compreensão e entusiasmo.

Aos meus familiares, oji, padrinhos, tios, tias, primos e parentes, que, direta ou indiretamente, ajudaram nessa caminhada com palavras de carinho e estímulo. Em especial, agradeço aos meus pais de Prudente, tia Eunice e tio Valter, e todos os familiares de PP, pelo apoio, suporte e acolhida de sempre.

Às minhas amigas, em especial, Elainezinha, Isa (irmãzinha), Bia, Re Tiemi, May e Kelly Mi (prima-amiga) pelo apoio, força e encorajamento, pelas conversas, risadas e distrações durante esse período. De forma geral e não menos especial, agradeço a todos os meus amigos, aqueles de longa data e aos que chegaram mais recentemente, pelas demonstrações de carinho e palavras de incentivo.

Ao meu namorado, Otávio, que me concede todo o suporte, apoio e amor para eu alcançar meus objetivos.

À toda mão estendida a mim ao longo do desenvolvimento deste trabalho, em especial, Daniel, Le Rosim, Gabi e Marcus, que me ajudaram muito nos processamentos, nos momentos em que me deparei com alguma dificuldade.

À Inspectral, que acredita e confia em mim e no meu trabalho. Agradeço por me permitirem ser parte dessa grande e incrível empreitada.

À Universidade Estadual Paulista, campus de Presidente Prudente (FCT-UNESP), e ao Programa de Pós-Graduação em Ciências Cartográficas (PPGCC), pela infraestrutura oferecida. Um agradecimento especial à Cinthia, que gentilmente sempre me orientou e auxiliou no que precisei.

A todos os professores do PPGCC, pelo conhecimento compartilhado, que contribuiu grandemente para a minha formação acadêmica.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

RESUMO

A construção de reservatórios ocasiona várias alterações ambientais, que favorecem o crescimento descontrolado de vegetação aquática, podendo comprometer os usos múltiplos da água. Assim, identificar essas plantas, bem como conhecer suas principais características e distribuição espacial, são informações importantes para fazer um plano de manejo adequado. Neste sentido, com o advento dos veículos aéreos remotamente pilotados no contexto do sensoriamento remoto, é possível obter imagens de alta resolução espacial que podem dar suporte no mapeamento de vegetação aquática. O alto nível de detalhamento dessas imagens permite extrair atributos de textura, uma característica importante da imagem que é utilizada para auxiliar na identificação de objetos ou regiões de interesse da superfície terrestre. Assim, este estudo teve por objetivo avaliar a capacidade de discriminação de diferentes espécies de vegetação aquática emersa (VAE) por meio da integração de atributos espectrais e de textura, pelo método de análise orientada a objeto, segmentação com Superpixel seguida de classificação dos segmentos com o algoritmo Random Forest. Uma das formas de extrair textura foi pela técnica Scale Invariant Feature Transform (SIFT), um algoritmo robusto da área de visão computacional. Os resultados mostraram que os atributos de textura são importantes, independente da procedência, mas que o SIFT teve um desempenho inferior em relação às texturas usualmente empregadas, como Grey-Level Co-occurrence Matrix. Classificar somente com atributos de textura levou à obtenção acurácias menores, mas ainda assim expressivas, indicando que utilizar apenas a informação de textura já explica parte das características intrínsecas de cada espécie. Os atributos de textura foram combinados com outros atributos e, ao final, a combinação de atributos espectrais e de textura não advinda do SIFT, índices de vegetação e densidade de pontos (textura SIFT) obteve a maior acurácia global e coeficiente Kappa, 95% e 0,92, respectivamente. Logo, a hipótese baseada na possibilidade de descrever as informações de organização espacial, estrutura da folha, particularidades de sombra etc. pelos atributos de textura foi confirmada, e quando combinados com atributos espectrais o ganho não foi tão considerável, mas foi comprovada sua importância na discriminação das espécies de VAE.

Palavras-chave: Vegetação aquática emersa, Atributos de textura, Object-based image analysis (OBIA), Scale invariant feature transform (SIFT).

ABSTRACT

The construction of reservoirs causes several environmental changes, which may lead to uncontrolled growth of aquatic vegetation, which in turn, might compromise the multiple uses of water. Therefore identifying these plants, as well as knowing their main characteristics and spatial distribution, is important information for making an appropriate management plan. With the advent of unmanned aerial vehicles in the context of remote sensing, it is possible to obtain high spatial resolution images that can support the mapping of aquatic vegetation. The high level of detail of these images allows the extraction of texture features, an important characteristic of the image that is used to help identify objects or regions of interest on the Earth's surface. Thus, this study aimed to evaluate the ability to discriminate between different species of emergent aquatic vegetation (EAV) by integrating spectral and texture features, using object-based image analysis, Superpixel segmentation, followed by Random Forest classification. The Scale Invariant Feature Transform (SIFT) technique was one of the ways used to extract texture, a robust computer vision algorithm. The results showed that texture features are important, regardless of origin, but that SIFT was not as consistent as common textures, such as the Grey-Level Co-occurrence Matrix. Classifying with texture features alone resulted in lower, but still significant, accuracies, indicating that by using texture information alone, part of the intrinsic characteristics of each EAV species can already be explained. The texture features were combined with other features and, in the end, the combination of spectral and texture features not derived from SIFT, vegetation indices and point density (texture feature from SIFT) obtained the highest overall accuracy and Kappa coefficient, 95% and 0.92, respectively. Therefore, the hypothesis based on the possibility of describing information on spatial organization, leaf structure, shade particularities etc. by texture features was confirmed, and when combined with spectral features the gain was not as considerable, but its importance in discriminating EVA species was proven.

Keywords: Emergent aquatic vegetation, Texture features, Object-based image analysis (OBIA), Scale invariant feature transform (SIFT).

LISTA DE FIGURAS

Figura 1 - Os cinco grupos ecológicas da vegetação aquática (macrófitas).....	20
Figura 2 - Curvas de reflectância de uma espécie de VAE, <i>Nuphar polysepalum</i> , de acordo com a porcentagem de sua cobertura espacial na água. Estudo feito por Jakubauskas et al. (2000).	22
Figura 3 - Representação de uma imagem de (a) baixa, (b) média e (c) alta resolução espacial em que os pixels são significativamente maiores que o objeto de interesse, possuem tamanhos equivalentes, e são significativamente menores que o objeto de interesse, respectivamente. .	24
Figura 4 - Esquema das etapas de OBIA.....	24
Figura 5 - Comparação dos algoritmos (a) Crescimento de Regiões, (b) Superpixel e (c) Watershed.	25
Figura 6 - Funcionamento do algoritmo Random Forest.	32
Figura 7 - Exemplo de matriz de confusão. V = vegetação; A = água; AU = área urbana.	33
Figura 8 - Uma oitava é composta por imagens gaussianas (filtradas), que são subtraídas duas a duas, de forma adjacente, na mesma escala, obtendo-se as imagens-diferença. A oitava seguinte redimensiona a imagem original pela metade do seu tamanho.	37
Figura 9 - Construção do descritor para um ponto-chave, determinado por uma vizinhança de 4×4 sub-regiões e 8 valores e orientação, obtendo um vetor de 128 valores.	38
Figura 10 - Localização da represa da Cica, situada entre os municípios de Álvares Machado e Presidente Prudente, no Estado de São Paulo.	40
Figura 11 - Câmara multiespectral, modelo Alpha 6000, com o sensor de sistema de duas cabeças.	41
Figura 12 - Receptor GNSS Reach M+.....	42
Figura 13 - VARP X800 GEO.....	43
Figura 14 - Fluxograma das etapas do método proposto neste estudo.	44
Figura 15 - Indicação da área de voo realizado na represa da Cica, de uma parcela do reservatório contendo VAE.	45
Figura 16 - (a) Localização dos três ortomosaicos no contexto da represa da Cica. Ortomosaicos (b) 1, (c) 2 e (d) 3, destacando os recortes (retângulos) extraídos.	47
Figura 17 - Localização do ortomosaico 2 no contexto da represa da Cica; (b) Ortomosaico 2 destacando o recorte de (c) uma área, denominada área teste, com a presença das três espécies de VAE e superfície d'água.....	48
Figura 18 - (a) Localização do ortomosaico 2 no contexto da represa da Cica, com a localização dos três recortes: (c) 1, (d) 2, e (e) 3.	49
Figura 19 - (a) Recorte 1 no nível original (0,8 cm). Subamostragem do recorte 1 para: (b) 1 cm; (c) 1,6 cm; (d) 2 cm; (e) 3 cm. Suavização do recorte 1 para: (f) $\sigma=2$; (g) $\sigma=4$; (h) $\sigma=8$. 51	

Figura 20 - (a) Recorte 6 com destaque para (b) um segmento com as três segmentações, sendo o contorno rosa, azul e branco, respectivamente, as combinações (1) $1,6 \text{ cm} + \sigma = 6$, (2) $2 \text{ cm} + \sigma = 6$ e (3) $3 \text{ cm} + \sigma = 4$; (c) Compatibilização do polígono com cada borda do segmento em destaque. Todas as imagens estão com o fundo do recorte no nível original. ...	53
Figura 21 - Efeito da super-segmentação utilizando três limiares de similaridade abaixo de 50 para o recorte 1, no nível original: (a) Similaridade: 20/Área: 200; (b) Similaridade: 30/Área: 200; (c) Similaridade: 40/Área: 200. Todas as segmentações estão com o fundo do recorte no nível original.	61
Figura 22 - Comparação da (a) subamostragem e (b) suavização quanto à quantidade de segmentos gerados a partir do algoritmo Crescimento de Regiões, utilizando os seguintes parâmetros: Similaridade: 70/Área: 200.	62
Figura 23 - As segmentações que conseguiram delinear melhor as espécies de cada recorte a partir do algoritmo Crescimento de Regiões, utilizando os seguintes parâmetros: Similaridade: 70/Área: 200. Recortes (a) 1, (b) 2 e (c) 3 para fins de comparação com a segmentação das subamostragens de (d) 3 cm, (e) 2 cm e (f) 3 cm, respectivamente. Todas as segmentações estão com o fundo do recorte no nível original.	64
Figura 24 - Comparação da segmentação dos recortes (a) 1, (b) 2 e (c) 3 entre as diferentes suavizações a partir do algoritmo Crescimento de Regiões, com os seguintes parâmetros: Similaridade: 70/Área: 200. (a) $\sigma=2$; (b) $\sigma=4$; (c) $\sigma=8$. Todas as segmentações com o fundo do recorte no nível original.	64
Figura 25 - Comparação da segmentação com Superpixel do recorte 1 no nível original, alterando os valores de compacidade: (a) 10 (padrão do algoritmo); (b) 250; (c) 500. Todas as segmentações estão com o fundo do recorte no nível original.	65
Figura 26 - Comparação da segmentação do recorte 2 entre as diferentes subamostragens a partir do algoritmo Superpixel, com os seguintes parâmetros: Compacidade: 10/Quantidade de segmentos: 50. (a) Recorte 2 para fins de visualização; (b) Nível original (0,8 cm); (c) 1 cm; (d) 1,6 cm; (e) 2 cm; (f) 3 cm. Todas as segmentações estão com o fundo do recorte no nível original.	66
Figura 27 - Comparação das subamostragens de 3 cm dos recortes (a) 1, (b) 2 e (c) 3 segmentadas a partir do algoritmo Superpixel, com os seguintes parâmetros: Compacidade: 10/Quantidade de segmentos: 50. Todas as segmentações estão com o fundo do recorte no nível original.	67
Figura 28 - Comparação da segmentação dos recortes (a) 1, (b) 2 e (c) 3 entre as diferentes suavizações a partir do algoritmo Superpixel, com os seguintes parâmetros: Compacidade: 10/Quantidade de segmentos: 50. (a) $\sigma=2$; (b) $\sigma=4$; (c) $\sigma=8$. Todas as segmentações estão com o fundo do recorte no nível original.	68
Figura 29 - Comparação de um mesmo segmento na (a) subamostragem (3 cm) e na (b) suavização ($\sigma=8$) do recorte 3 para o algoritmo Superpixel, com os seguintes parâmetros: Compacidade: 10/Quantidade de segmentos: 50. Todas as segmentações estão com o fundo do recorte no nível original.	68
Figura 30 - Comparação da (a) subamostragem e (b) suavização quanto à quantidade de segmentos gerados a partir do algoritmo Watershed, utilizando os seguintes parâmetros: Depth threshold: 0,01/Flood level: 0,3.	69

Figura 31 - Comparação da segmentação dos recortes (d) 1, (e) 2 e (f) 3 entre as subamostragens de 3 cm a partir do algoritmo Watershed, com os seguintes parâmetros: Depth threshold: 0,01/Flood level: 0,3. Recortes 1, (b) 2 e (c) 3 para fins de visualização. Todas as segmentações estão com o fundo do recorte no nível original.	70
Figura 32 - Comparação da segmentação dos recortes (a) 1, (b) 2 e (c) 3 entre as diferentes suavizações a partir do algoritmo Watershed, com os seguintes parâmetros: Depth threshold: 0,01/Flood level: 0,3. (a) $\sigma=2$; (b) $\sigma=4$; (c) $\sigma=8$. Todas as segmentações estão com o fundo do recorte no nível original.	71
Figura 33 - Extração de 499 pontos-chave do recorte 1 subamostrado para 3 cm. (a) Localização dos pontos-chave (b) delimitados pelos segmentos, que englobam vários deles. As duas figuras estão com o recorte original, para a melhor visualização.....	74
Figura 34 - Mapa de classificação para o conjunto de dados 1 (descritores de textura SIFT), exibido com as classes divididas em segmentos.....	88
Figura 35 - Mapa de classificação para o conjunto de dados 1 (descritores de textura SIFT), exibido com as classes dissolvidas.	88
Figura 36 - Mapa de classificação para o conjunto de dados 2 (atributos de textura do GeoDMA).....	89
Figura 37 - Mapa de classificação para o conjunto de dados 3 (atributos espectrais do GeoDMA).....	90
Figura 38 - Mapa de classificação para o conjunto de dados 6 (atributos espectrais e de textura do GeoDMA, índices de vegetação e densidade de pontos).	91
Figura 39 - Comparação da classificação dos conjuntos de dados (a) 2, (b) 3 e (c) 6 da (d) área teste. AG = Acurácia Global; CK = Coeficiente Kappa.	92

LISTA DE TABELAS

Tabela 1 - Especificações do sensor de sistema de duas cabeças, modelo Alpha 6000.	41
Tabela 2 - Especificações do receptor GNSS Reach M+.....	42
Tabela 3 - Especificações do VARP X800 GEO.....	43
Tabela 4 - Especificações dos parâmetros da aquisição das imagens.....	45
Tabela 5 - Atributos gerados pela ferramenta GeoDMA.	55
Tabela 6 - Discriminação do número de segmentos para treinamento e validação, por classe temática.	57
Tabela 7 - Descrição da composição dos conjuntos de dados criados para a classificação.	59
Tabela 8 - Comparação entre as segmentações com as três combinações de subamostragem e suavização do algoritmo Superpixel, com o maior valor de Precisão destacado em negrito. CL = coluna/linha; ID = identificador do segmento.....	72
Tabela 9 - Os atributos selecionados do GeoDMA: 10 atributos de cada banda (azul, verde, vermelho e IVP), totalizando-se 40 atributos.....	73
Tabela 10 - Valores internos dos vetores descritores (pontos-chave) obtidos por SIFT, referente à Figura 33.	75
Tabela 11 - Cálculo do coeficiente de variação, média e mediana dos descritores dos pontos-chave pertencentes a um mesmo segmento (ID 0), para a obtenção de um ponto-chave sintético do recorte 1 subamostrado para 3 cm.....	75
Tabela 12 - Desempenho da classificação dos descritores de textura SIFT para os 6 pontos-chave sintéticos, variando o número de árvores, demonstrado pela Acurácia Global (AG) e Coeficiente Kappa (CK). O ponto-chave sintético com o maior desempenho (2cm_média) está em negrito.....	76
Tabela 13 - Desempenho do treinamento dos diferentes conjuntos de dados utilizando Validação Cruzada, variando o número de árvores, descrito pela Acurácia Global (AG) e Coeficiente Kappa (CK). Os maiores valores de cada conjunto de dados estão em negrito. ..	77
Tabela 14 - Desempenho da classificação dos 8 conjuntos de dados, utilizando 300 árvores, descrito pela Acurácia Global e Coeficiente Kappa.	78
Tabela 15 - Matriz de confusão calculada para a classificação do conjunto de dados 1 com 128 atributos (somente os descritores de textura SIFT). AG = Acurácia Global; CK = Coeficiente Kappa.....	78
Tabela 16 - Matriz de confusão calculada para a classificação do conjunto de dados 2 com 16 atributos (apenas os atributos de textura do GeoDMA – coeficiente de variação, contraste, dissimilaridade e entropia). AG = Acurácia Global; CK = Coeficiente Kappa.	79
Tabela 17 - Matriz de confusão calculada para a classificação do conjunto de dados 3 com 24 atributos (atributos espectrais do GeoDMA). AG = Acurácia Global; CK = Coeficiente Kappa.	79

Tabela 18 - Matriz de confusão calculada para a classificação do conjunto de dados 6 com 43 atributos (atributos espectrais e de textura do GeoDMA, índices de vegetação e densidade de pontos). AG = Acurácia Global; CK = Coeficiente Kappa.	80
Tabela 19 - Comparação das classificações considerando os atributos de textura do GeoDMA com os do SIFT, adicionando os demais atributos gradualmente. O atributo densidade de pontos foi o que mais contribuiu para o aumento da acurácia global, destacado em negrito. .	81
Tabela 20 - Matriz de confusão calculada para a classificação do conjunto de dados 7 com 152 atributos (atributos espectrais do GeoDMA e descritores de textura SIFT). AG = Acurácia Global;.....	81
Tabela 21 - Matriz de confusão calculada para a classificação do conjunto de dados 8 com 171 atributos (atributos espectrais e de textura do GeoDMA, índices de vegetação, densidade de pontos, e descritores de textura SIFT). AG = Acurácia Global; CK = Coeficiente Kappa.	81
Tabela 22 - Número de pontos por recorte com a especificação das espécies presentes.	82
Tabela 23 - Súmula das acurácias do produtor e usuário da classificação de todos os conjuntos de dados.....	83
Tabela 24 - Comparativo da incorporação de atributos de textura do GeoDMA e descritores de textura SIFT, índices de vegetação e densidade de pontos, camada por camada, aos atributos espectrais. AE = atributos espectrais; AT = atributos de textura; IV = índices de vegetação; DP = densidade de pontos.....	84
Tabela 25 - Desempenho da classificação da área teste para os 8 conjuntos de dados.	85
Tabela 26 - Súmula das acurácias do produtor e usuário da classificação de todos os conjuntos de dados para a área teste.	86

SUMÁRIO

1	INTRODUÇÃO	16
1.1	Objetivos	19
2	FUNDAMENTAÇÃO TEÓRICA	20
2.1	Vegetação Aquática Emersa	20
2.2	Sensoriamento Remoto de Vegetação Aquática Emersa	21
2.3	Índices espectrais de vegetação	22
2.4	Análise Orientada a Objeto	23
2.4.1	Segmentação	25
2.4.1.1	Crescimento de Regiões	26
2.4.1.2	Superpixel	26
2.4.1.3	Watershed	28
2.4.2	Classificação	28
2.4.2.1	Seleção de Atributos	29
2.4.2.2	Aprendizado de Máquina: Random Forest	30
2.4.2.3	Matriz de Confusão	32
2.5	Textura em imagem	34
2.6	Scale Invariant Feature Transform (SIFT)	35
2.6.1	Detecção de extremos no espaço-escala	36
2.6.2	Localização de pontos-chave	37
2.6.3	Definição da orientação	38
2.6.4	Descrição dos pontos-chave	38
3	MATERIAIS E MÉTODOS	38
3.1	Área de estudo	39
3.2	Materiais	40
3.2.1	Câmara multiespectral	41
3.2.2	Receptor GNSS	42
3.2.3	Veículo Aéreo Remotamente Pilotado (VARP)	42
3.3	Método	43
3.3.1	Aquisição de imagens e processamento fotogramétrico para a obtenção de ortomosaicos	44
3.3.2	Extração de recortes a partir dos ortomosaicos	46
3.3.3	Segmentação: Seleção do algoritmo de segmentação	48
3.3.4	Segmentação: Avaliação da acurácia da segmentação	51
3.3.5	Extração de atributos espectrais e de textura	54
3.3.6	Seleção de atributos do GeoDMA e síntese dos descritores de textura SIFT	56
3.3.7	Classificação	57
4	RESULTADOS E DISCUSSÃO	61
4.1	Segmentação	61
4.1.1	Experimento 1: Crescimento de Regiões	61
4.1.2	Experimento 2: Superpixel	65
4.1.3	Experimento 3: Watershed	69

4.1.4	Seleção do algoritmo e avaliação da acurácia da segmentação	71
4.2	Classificação.....	73
4.2.1	Recortes.....	73
4.2.1.1	Seleção de atributos do GeoDMA e síntese dos descritores de textura SIFT 73	
4.2.1.2	Classificação dos descritores de textura SIFT	76
4.2.1.3	Classificação dos diferentes conjuntos de dados	77
4.2.1.4	Contribuição dos atributos para a discriminação das espécies de VAE.....	82
4.2.2	Área teste – mapa de classificação	85
5	CONCLUSÕES	93
	REFERÊNCIAS.....	95

1 INTRODUÇÃO

A construção de reservatórios provoca inúmeras alterações ambientais, duas delas sendo a redução da turbulência da água e o aumento da concentração de nutrientes, que favorecem o crescimento de vegetação aquática (ESTEVES, 1998; THOMAZ, 2002). Essas plantas são importantes na dinâmica dos ecossistemas aquáticos, pois atuam como “filtro” nas primeiras porções mais próximas à margem, permitindo a sedimentação de materiais presentes na água, bem como são produtoras primárias. No entanto, o seu crescimento descontrolado ocasiona consequências negativas para o ambiente aquático, comprometendo, em grande parte, seus usos múltiplos (ESTEVES, 1998).

Segundo Esteves (1998), como consequência das modificações, juntamente de condições climáticas favoráveis e ausência de organismos competidores e predadores, muitas espécies podem apresentar alta taxa de crescimento, tal como, o aguapé (*Eicchornia crassipes*). Diante disso, identificar a vegetação aquática, assim como conhecer suas principais características e distribuição espacial, são informações importantes para fazer um plano de manejo adequado (NICHOLS, 1991; THOMAZ, 2002; POMPÊO, 2017).

Neste sentido, o sensoriamento remoto tem sido muito utilizado para estudos envolvendo a detecção e mapeamento de vegetação aquática, utilizando imagens de satélites (PROCTOR et al., 2013; VILLA et al., 2015; QING et al., 2020; ADE et al., 2022; PIASER; VILLA, 2023) e imagens adquiridas de veículos aéreos remotamente pilotados (HUSSON et al., 2016; CHABOT et al., 2018; BENJAMIN et al., 2021; BOLCH et al., 2021; ZHOU et al., 2021).

A utilização de veículos aéreos remotamente pilotados (VARPs), como plataforma móvel, possibilita a obtenção de imagens de alta resolução espacial, as quais têm demonstrado potencial para identificar vegetação aquática com detalhamento da espécie, como nos estudos realizados por Husson et al. (2016), Chabot et al. (2018), Benjamin et al. (2021), Bolch et al. (2021) e Zhou et al. (2021). Em relação aos estudos que utilizaram imagens de satélite, a maioria discerne a vegetação aquática apenas pelo grupo ecológico: vegetação aquática emersa (VAE) e vegetação aquática submersa (VAS) (VILLA et al., 2015; QING et al., 2020; ADE et al., 2022; PIASER; VILLA, 2023), o que se deve à limitação da resolução espacial (10 a 30 m).

As imagens obtidas de VARPs possuem resolução espacial em unidade centimétrica ou até milimétrica (ALVAREZ-VANHARD et al., 2021), permitindo capturar maiores detalhes. Segundo Blaschke (2010), com o aumento da resolução espacial das imagens, o tamanho do pixel passou a ser consideravelmente menor que o objeto de interesse da superfície terrestre,

tornando-se relevante agrupar os pixels em objetos, e assim, surgindo a análise orientada a objeto (Object-Based Image Analysis – OBIA), composta pelas etapas de segmentação e classificação.

Vários estudos desenvolvidos para mapear vegetação aquática utilizaram a abordagem OBIA (HUSSON et al., 2016; PANDE-CHHETRI et al., 2017; CHABOT et al., 2018; VISSER et al., 2018; BENJAMIN et al., 2021; BOLCH et al., 2021; JIANG et al., 2021; ZHOU et al., 2021). Blaschke (2010) fez o levantamento de vários estudos que obtiveram maior acurácia utilizando a abordagem OBIA do que a abordagem pixel-a-pixel em diversas aplicações.

O estudo realizado por Pande-Chhetri et al. (2017) comparou os dois tipos de abordagem para classificar dois tipos de VAE: aguapé (*Eichhornia crassipes*) e alface d'água (*Pistia stratiotes*) em uma área de um lago, localizado no Sul da Flórida, nos Estados Unidos. Os autores utilizaram imagens RGB (Red, Green, Blue – vermelho, verde, azul), com uma resolução espacial de 8 cm, e os resultados mostraram que o desempenho da abordagem OBIA, utilizando Support Vector Machines, Artificial Neural Network e Máxima Verossimilhança, foi superior à abordagem pixel-a-pixel, utilizando os mesmos classificadores.

Random Forest é um algoritmo de aprendizado de máquina, assim como Support Vector Machines e Artificial Neural Network, também empregado na abordagem OBIA para classificar vegetação aquática (HUSSON et al., 2016; CHABOT et al., 2018; BENJAMIN et al., 2021; BOLCH et al., 2021; ZHOU et al., 2021). No estudo realizado por Ma et al. (2017), que fez uma revisão bibliográfica de 173 artigos publicados sobre a classificação de cobertura da terra por OBIA, Random Forest foi constatado como o algoritmo com melhor desempenho, pois é mais robusto ao trabalhar com grande quantidade de dados e atributos, requer menos parâmetros para serem definidos e é mais rápido que Support Vector Machines e outros classificadores do tipo ensemble (BELGIU; DRAGUT, 2016; MAXWELL et al., 2018).

Além disso, a abordagem OBIA permite integrar o uso de atributos de textura na classificação. No contexto do sensoriamento remoto, a textura permite descrever a relação e a distribuição dos tons de cinza dado um agrupamento de pixels, utilizada para identificar objetos ou regiões de interesse na imagem (HARALICK et al., 1973; IRONS; PETERSEN, 1981). Hay et al. (1996) complementa que a textura está relacionada à resolução espacial das imagens, sendo mais coerente nas análises de imagens de maior resolução espacial.

Os estudos realizados por Husson et al. (2016), Chabot et al. (2018), Benjamin et al. (2021), Bolch et al. (2021) e Zhou et al. (2021) têm em comum a metodologia de classificação de VAE pela abordagem OBIA (segmentação seguida da classificação), utilizando Random Forest como classificador. Ainda, todos eles incorporam atributos de textura, a maioria derivada

da Grey-Level Co-occurrence Matrix (GLCM), e apontam de forma geral que a textura contribui de alguma forma na classificação de espécies de VAE.

O estudo de Husson et al. (2016) foi feito em cinco locais teste no lago Ostrträsket, localizado no norte da Suécia, para avaliar a eficiência do mapeamento automatizado de VARP a partir de imagens RGB de sete espécies de VAE. A acurácia global das classificações variou de 52% a 69%, notando-se menores valores de acurácia nos locais teste com maior complexidade na mistura das espécies. Chabot et al. (2018), por sua vez, realizaram um estudo em Ontário, Canadá, para classificar e diferenciar *Stratiotes aloides*, em seu estágio VAS e VAE, de outras espécies inseridas de forma generalizada nas classes VAE e VAS, atingindo-se 92% de acurácia global. O objetivo dos autores foi criar um fluxograma de processamento que facilitasse o monitoramento de vegetação aquática.

Benjamin et al. (2021) conduziram um estudo para monitorar a eficácia no manejo de *Nymphoides cristata*, na Flórida, Estados Unidos. O propósito foi determinar os parâmetros ótimos de planejamento de voo de VARP e métodos de processamento de imagem adequados, com a finalidade de estimar a eficiência e acurácia do monitoramento do comportamento da VAE de interesse em um ambiente controlado, levando em consideração boas práticas de manejo que sejam escaláveis. Assim, a classificação obteve acurácia global de 89,6% a 95,4%.

Bolch et al. (2021) compararam dois imageadores diferentes, um embarcado em veículo aéreo tripulado e outro em VARP, para mapear sistemas aquáticos na Califórnia, Estados Unidos. O estudo conseguiu discriminar *Eichhornia crassipes* e *Ludwigia peploides*, enquanto generalizou VAS em apenas uma classe. O imageador montado no VARP obteve uma acurácia global de 94,10% e conseguiu detectar pequenas porções com presença de aguapé não detectadas pelo outro método de mapeamento, o qual alcançou acurácia global de 86,7%, já praticado pelas agências locais de monitoramento.

Zhou et al. (2021) fizeram um estudo no lago Honghu, na província de Hubei, China. O objetivo foi identificar um método acurado e com custo-benefício vantajoso na classificação de sete espécies de vegetação aquática, utilizando imagens RGB obtidas a partir de VARP e avaliando a contribuição do uso de vários tipos de atributos e algoritmos de aprendizado de máquina. Os autores testaram cinco algoritmos: Árvores de Decisão, Bayes, K-Nearest Neighbor, Random Forest e Support Vector Machines, sendo que Random Forest obteve o melhor desempenho ao considerar todos os atributos, com acurácia global de 89,76%, ao passo que ao selecionar os atributos, subiu para 90,73%.

Em vista disso, notou-se que os atributos de textura são pouco explorados na aplicação de classificação de VAE e são mais comumente utilizados aqueles provindos da matriz GLCM. Uma outra forma de extrair atributos de textura pode ser pela técnica Scale Invariant Feature Transform (SIFT) (LOWE, 1999, 2004), um algoritmo robusto da área de visão computacional originalmente utilizado para a correspondência de pontos homólogos no reconhecimento de objetos, também admitida em diferentes aplicações envolvendo vegetação.

Kebapci et al. (2011) utilizaram imagens de plantas terrestres para serem comparadas com um banco de dados de plantas de mesmo tipo, buscando correspondência por SIFT. Wilf et al. (2016) conduziram um estudo similar, investigando o uso de SIFT na tarefa de reconhecimento de folhas de angiospermas para classificá-las, enquanto Pires et al. (2016), Rançon et al. (2019) e Blanco et al. (2020) utilizaram SIFT na agricultura. Nos dois primeiros, a aplicação foi para a detecção de doenças no cultivo de soja e plantação de videiras, respectivamente, e o terceiro estudo empregou a textura SIFT na classificação de diferentes tipos de cultivos.

Os estudos previamente apontados indicaram ser possível obter resultados promissores com a técnica SIFT, e sua aplicação na classificação de vegetação aquática ainda não foi encontrada na literatura. Sendo assim, a hipótese deste estudo é que seja possível descrever algumas características importantes de VAE (organização espacial, estrutura da folha, particularidades de sombra etc.) pelos atributos de textura, e quando combinados com atributos espectrais, contribuam para a identificação dessas espécies.

Este estudo está organizado nas seguintes seções: fundamentação teórica, onde constam todos os conceitos teóricos pertinentes; materiais e métodos, que descreve todos os recursos utilizados para a realização deste estudo e como foi conduzido; resultados e discussão, onde encontra-se um compilado de tudo o que foi obtido; e por fim, as conclusões.

1.1 Objetivos

O objetivo geral deste estudo é avaliar a capacidade de discriminação de diferentes espécies de VAE por meio da integração de atributos espectrais e de textura de imagens de alta resolução espacial, classificadas com Random Forest. Sendo os seguintes objetivos específicos:

- Analisar o comportamento de três algoritmos de segmentação quando aplicados em imagens de alta resolução contendo VAE;
- Verificar o potencial do uso da textura SIFT na discriminação de espécies de VAE;
- Avaliar a contribuição de atributos de textura para discriminar espécies de VAE;

- Avaliar a qualidade dos resultados obtidos pelo algoritmo de aprendizado de máquina Random Forest.

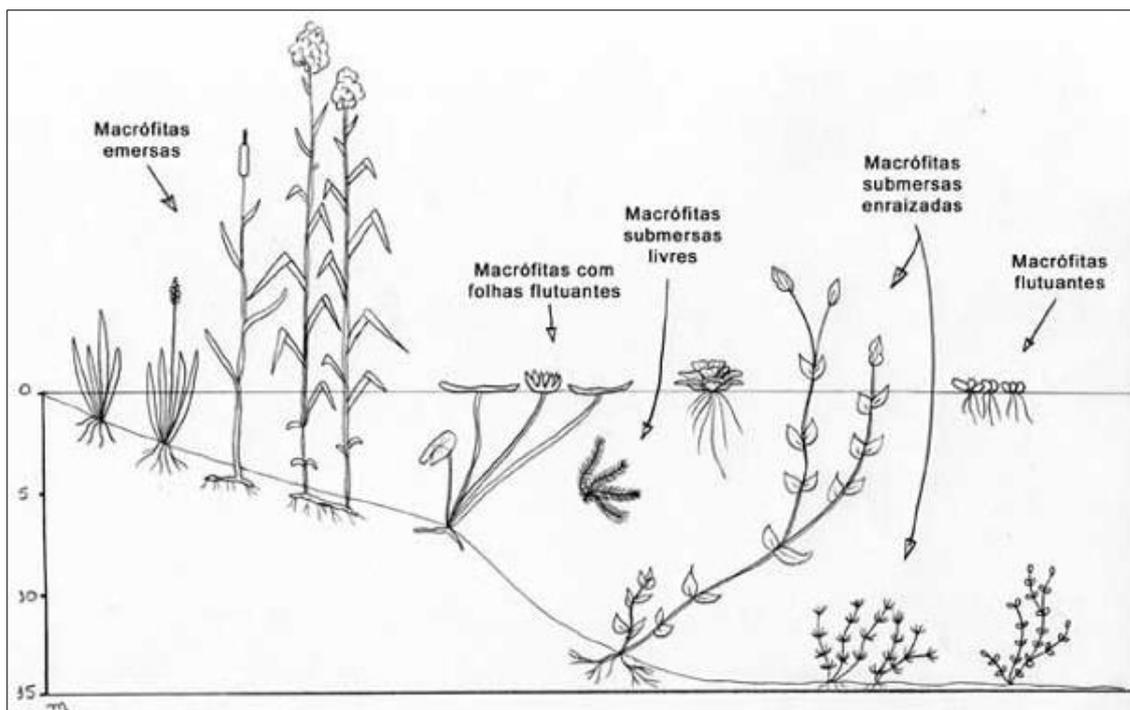
2 FUNDAMENTAÇÃO TEÓRICA

Esta seção apresenta a caracterização de VAE, especificando seu comportamento espectral no contexto do sensoriamento remoto, e o uso de índices espectrais de vegetação. Explicita a abordagem OBIA, segmentação e classificação, adentrando no funcionamento de três algoritmos de segmentação e em conceitos importantes dentro da classificação. Além disso, esclarece a concepção de textura e a técnica de extração de descritores de textura SIFT.

2.1 Vegetação Aquática Emersa

De acordo com Esteves (1998), a vegetação aquática consiste em plantas que retornaram do ambiente terrestre para o ambiente aquático, detendo grande capacidade de adaptação e importância ecológica. O autor divide a vegetação aquática em cinco grupos ecológicos: submersas enraizadas; submersas livres; emersas enraizadas; enraizadas com folhas flutuantes; e flutuantes (Figura 1).

Figura 1 - Os cinco grupos ecológicos da vegetação aquática (macrófitas).



Fonte: Esteves (1998)

A vegetação aquática pode distribuir-se de forma organizada das margens para o interior dos lagos, iniciando pelas emersas enraizadas, seguidas pelas submersas enraizadas e emersas com folhas flutuantes até chegar naquelas que se locomovem pela massa d'água desprendidas de substratos. Contudo, na maioria dos casos, a distribuição é heterogênea em decorrência de fatores ambientais (ESTEVEES, 1998). Essas plantas são fundamentais na dinâmica dos ecossistemas aquáticos, dentre as suas diversas funções, servem como alimento e abrigo para a fauna aquática; são responsáveis pela estocagem e ciclagem de materiais, principalmente as plantas enraizadas; além disso, são parte importante dos ciclos biogeoquímicos.

Todos os papéis ecológicos desenvolvidos pela vegetação aquática são fundamentais, contudo, seu crescimento descontrolado pode transformá-la em “praga”, principalmente em reservatórios (ESTEVEES, 1998). A espécie de VAE usualmente conhecida como aguapé (*Eichhornia crassipes*) é uma das mais associadas a problemas de superpopulação. Portanto, uma vez que a vegetação aquática se torna um problema de tal ordem, torna-se necessário realizar o controle, isto é, elaborar um plano de manejo. Para isso, deve-se conhecer suas principais características: fisiologia e morfologia, papel ecológico desenvolvido dentro do seu habitat e distribuição espacial (NICHOLS, 1991; THOMAZ, 2002; POMPÊO, 2017). Todas essas informações são importantes para traçar o plano de manejo mais adequado.

2.2 Sensoriamento Remoto de Vegetação Aquática Emersa

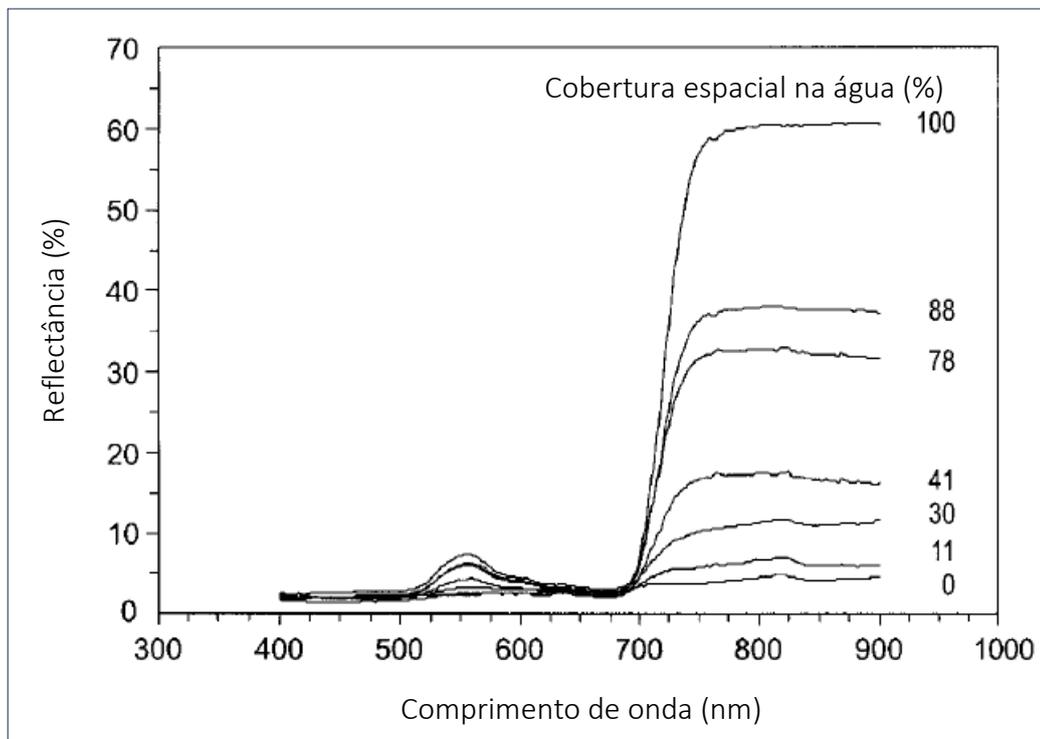
As vegetações aquática e terrestre possuem um comportamento espectral muito similar, definido basicamente por duas regiões: espectro visível (azul, verde e vermelho) e infravermelho próximo (IVP), com um pico usual na região do verde e no IVP (SILVA et al., 2008). A vegetação, quando sadia, absorve mais energia no comprimento de onda do azul e vermelho, devido à presença de clorofila, principal pigmento fotossintético das plantas. Em condições de estresse, a vegetação absorve menos energia na região do azul e vermelho, e a reflectância aumenta significativamente no comprimento de onda do vermelho (GOVENDER et al., 2007).

A reflectância da vegetação no espectro eletromagnético é determinada pelas características morfológicas e químicas das plantas (SILVA et al., 2008), diferenciando-se dentre as espécies. No caso da vegetação aquática, a reflectância da VAE geralmente é maior do que da VAS, porque não sofre com a atenuação da água, mas uma variabilidade nos valores de reflectância pode ser introduzida devido à mistura de sinal de água e planta, o que depende da densidade da vegetação e da estrutura da copa (JAKUBAUSKAS et al., 2000; SILVA et al.,

2008). Além disso, Silva et al. (2008) aponta que outras variabilidades na reflectância também podem ser causadas por estágios fenológicos diferentes.

Jakubauskas et al. (2000) investigaram o comportamento espectral de uma espécie de VAE, *Nuphar polysepalum*, e verificaram que, conforme a porcentagem de cobertura vegetal da espécie diminuiu, expondo mais regiões de água, a reflectância também diminuiu (Figura 2). Ainda é possível observar o comportamento espectral da vegetação, descrito anteriormente, em que os picos estão localizados na região do verde (500-600 nm) e IVP (a partir de 700 nm), intervalos apontados especificamente pelo estudo.

Figura 2 - Curvas de reflectância de uma espécie de VAE, *Nuphar polysepalum*, de acordo com a porcentagem de sua cobertura espacial na água. Estudo feito por Jakubauskas et al. (2000).



Fonte: Adaptado de Jakubauskas et al. (2000)

2.3 Índices espectrais de vegetação

Os índices espectrais combinam valores dos pixels das bandas, levando em consideração o comportamento espectral da vegetação, com a finalidade de realçá-la na imagem (XUE; SU, 2017). Entre eles, Razão Simples (RS), originalmente do inglês Ratio Vegetation Index, e Normalized Difference Vegetation Index (NDVI) são amplamente utilizados (XUE; SU, 2017). Jordan (1969) propôs o índice RS (Equação 1) e Rouse et al. (1974), o NDVI (Equação 2).

$$RS = \frac{NIR}{R} \quad (1)$$

$$NDVI = \frac{NIR - R}{NIR + R} \quad (2)$$

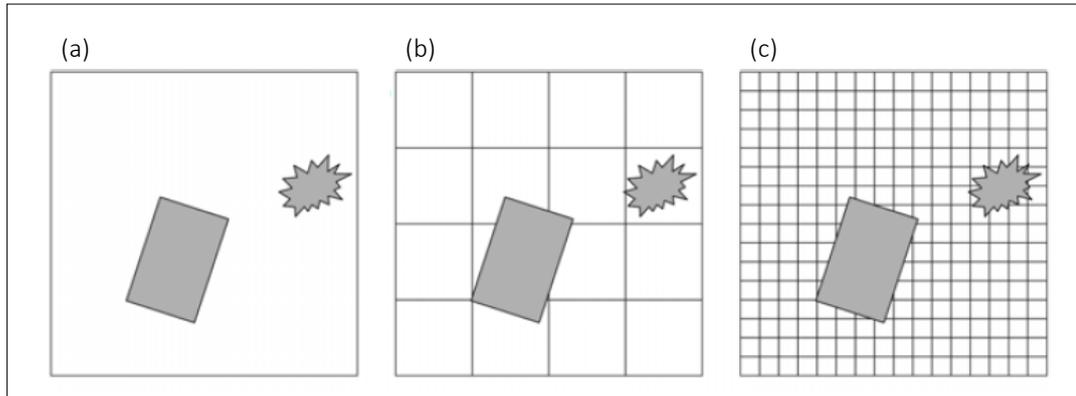
Ambos combinam a característica da absorção máxima de energia no comprimento de onda do vermelho (R – Red) pela clorofila, com a baixa absorção no IVP (NIR – Near Infrared), isto é, a alta reflectância (MYNENI et al., 1995). São comumente utilizados em estudos de vegetação terrestre (aplicações em agricultura, floresta etc.), sobretudo o NDVI, o qual se caracteriza por ser um índice normalizado, variando de 0 a 1, que informa sobre o crescimento e vigor da cobertura vegetal (XUE; SU, 2017).

2.4 Análise Orientada a Objeto

A Análise Orientada a Objeto (Object-Based Image Analysis – OBIA) surgiu no contexto do sensoriamento remoto devido ao aumento da resolução espacial das imagens, que ocasiona o aumento da variabilidade espectral interna entre os próprios alvos homogêneos da superfície (BLASCHKE, 2010). Nessas imagens, o tamanho do pixel é menor quando comparado ao objeto de interesse, portanto, é necessária uma etapa para tornar os pixels mais compreensíveis no contexto da imagem (BLASCHKE et al., 2014).

A Figura 3 apresenta uma ilustração feita por Blaschke (2010), que explica a relação entre os objetos de interesse da superfície terrestre e a resolução espacial. O autor descreve que as Figuras 3a-c representam uma imagem de baixa, média e alta resolução espacial, respectivamente, em que os pixels são significativamente maiores que os objetos de interesse na Figura 3a, possuem tamanhos equivalentes na Figura 3b, e os pixels são significativamente menores que os objetos de interesse na Figura 3c, tornando-se mais relevante agrupá-los.

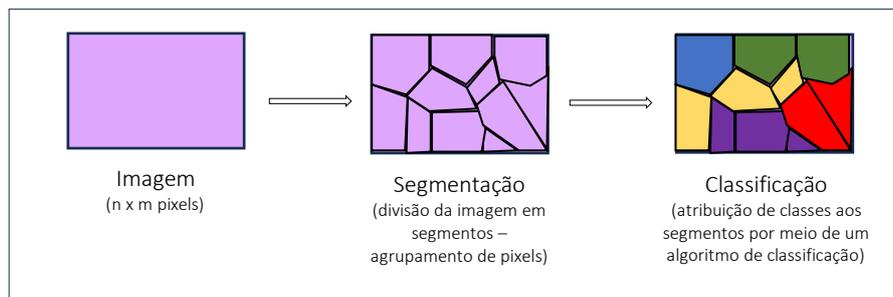
Figura 3 - Representação de uma imagem de (a) baixa, (b) média e (c) alta resolução espacial em que os pixels são significativamente maiores que o objeto de interesse, possuem tamanhos equivalentes, e são significativamente menores que o objeto de interesse, respectivamente



Fonte: Adaptado de Blaschke (2010)

As duas etapas de OBIA estão esquematizadas na Figura 4, sendo a segmentação a primeira delas, a qual consiste em particionar a imagem em regiões homogêneas, isto é, agrupar pixels em grupos (objetos) que tenham significado e contribuam na análise de contexto espacial, quando comparado ao uso do pixel isolado como unidade de análise (BLASCHKE, 2010; BLASCHKE et al., 2014). A segunda etapa trata-se da classificação dos objetos segmentados no procedimento anterior (HOSSAIN; CHEN, 2019).

Figura 4 - Esquema das etapas de OBIA.



Fonte: Adaptado de Blaschke et al. (2014)

Um dos objetivos de agrupar pixels em objetos é para solucionar o efeito de sal-pimenta nas imagens (BLASCHKE et al., 2000; BLASCHKE, 2010), que influencia diretamente na qualidade da classificação, etapa seguinte da segmentação (GAO et al., 2007). Como apontado por Blaschke (2010), a classificação no contexto de OBIA pode oferecer melhora significativa na acurácia, comparado à classificação pixel-a-pixel. Logo, obter uma segmentação de qualidade é fundamental (GAO et al., 2007; LI et al., 2010).

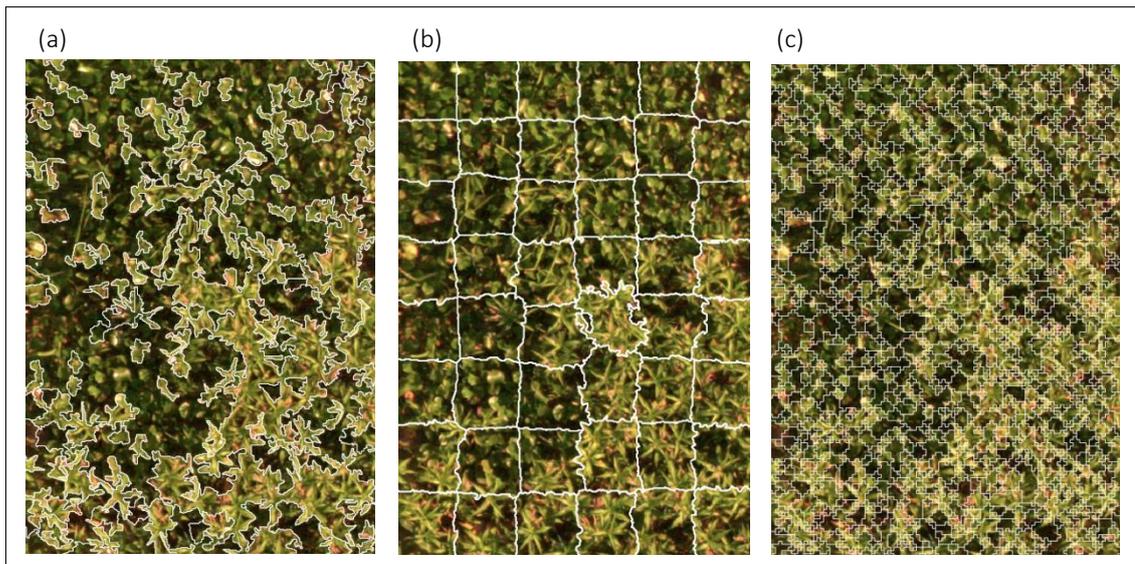
2.4.1 Segmentação

Existem diferentes abordagens para realizar a segmentação. A similaridade entre pixels dá origem à segmentação baseada em região, em que os segmentos são gerados enquanto houver pixels similares para serem agregados a partir de pixels-sementes (SCHIEWE, 2002; LI et al., 2010). Por sua vez, a descontinuidade origina a segmentação baseada em bordas, em que os segmentos são formados conforme vão contornando-as (SCHIEWE, 2002; LI et al., 2010).

Independente da abordagem, a segmentação pode apresentar problemas de super-segmentação (over-segmentation) e de sub-segmentação (under-segmentation). De acordo com Schiewe (2002), a super-segmentação cria muitos segmentos pequenos que não correspondem ao que visualmente se almeja. Por outro lado, pode ocorrer a sub-segmentação, gerando-se segmentos maiores e em quantidade inferior ao que visualmente é esperado.

Nesta seção, são especificados três algoritmos de segmentação: Crescimento de Regiões (BINS et al., 1996), Superpixel (ACHANTA et al., 2012) e Watershed (BEUCHER; LANTUEJOUL, 1979; KORNILOV; SAFONOV, 2018). Os dois primeiros são baseados em regiões, e o terceiro é um algoritmo baseado em bordas (SCHIEWE, 2002; HOSSAIN; CHEN, 2019), todos eles usualmente utilizados na literatura, em vários estudos, como levantado por Hossain e Chen (2019). A Figura 5 exemplifica a aplicação desses três algoritmos em uma mesma imagem contendo VAE.

Figura 5 - Comparação dos algoritmos (a) Crescimento de Regiões, (b) Superpixel e (c) Watershed.



2.4.1.1 Crescimento de Regiões

O algoritmo Crescimento de Regiões foi proposto por Bins et al. (1996), implementado no software Geographic Information and Image Processing System (SPRING), e apontado pelos autores como tecnicamente viável para a segmentação de imagens de áreas de agricultura e floresta.

O funcionamento consiste, primeiramente, na criação de n regiões preliminares contendo apenas um pixel, pois n corresponde ao número de pixels na imagem (pontos sementes). Cada região se expande iterativamente a partir de um critério de similaridade, nesse caso, a distância euclidiana mínima entre os valores de média de cada região, até que todos os pixels sejam processados. As regiões são analisadas duas a duas e devem ser espacialmente adjacentes, serão agrupadas se atenderem ao critério de similaridade. Cada vez que uma região é agregada à outra, a média é recalculada e atualizada para a nova região formada. O mesmo procedimento é repetido até que as regiões não possam mais ser mescladas.

O limiar de similaridade deve ser definido manualmente pelo usuário. A definição de um limiar muito baixo pode causar a super-segmentação, bem como a configuração de um limiar muito alto pode ocasionar a sub-segmentação. Na etapa final, regiões pequenas são agrupadas com regiões adjacentes maiores, conforme um limiar de área também definido pelo usuário. A definição desses parâmetros depende fortemente dos dados e de cada aplicação.

2.4.1.2 Superpixel

O algoritmo Superpixel utilizado neste estudo foi proposto por Achanta et al. (2012), denominado Simple Linear Iterative Clustering (SLIC), uma adaptação do algoritmo K-médias. SLIC é muito conhecido e empregado pela facilidade no uso, capacidade de aderir às bordas, rapidez no processamento e eficiência computacional.

Por padrão, exige-se a definição do parâmetro k , que corresponde ao número desejado de agrupamentos que aproximadamente serão formados. Definido o valor de k , gera-se uma grade regular com espaçamento S ($S = \sqrt{N/k}$) entre os centros iniciais (pontos sementes) dos agrupamentos, sendo N o número de pixels na imagem. Cada centro inicial é representado por $C_i = [l_i, a_i, b_i, x_i, y_i]^T$, em que $[l \ a \ b]^T$ refere-se ao espaço de cores CIELAB e $[x \ y]^T$ à posição do pixel.

Antes de iniciar a formação de superpixels, o algoritmo move os centros para posições de menor gradiente em uma vizinhança de 3x3, para evitar que os segmentos sejam gerados em bordas e reduzir a chance de um ponto semente ser um ruído. Cada pixel i é associado ao agrupamento mais próximo que sobrepõe sua localização na região de busca, delimitada a uma distância de $2S$ da vizinhança; o algoritmo K-médias, por sua vez, compara cada pixel i com todos os agrupamentos da imagem, independente da distância. Essa é uma das características que diferencia os dois algoritmos, e que acelera o processamento do SLIC.

Conforme os agrupamentos admitem novos pixels, a média é recalculada e atualizada, sendo que o procedimento é repetido iterativamente até a convergência do erro, que é calculado a cada iteração. A última etapa exige que pixels disjuntos sejam necessariamente atribuídos a algum superpixel próximo a eles. O cálculo da distância (Equação 3) é a combinação da proximidade de cor (Equação 4) com a proximidade de espaço (Equação 5).

$$D = \sqrt{d_c^2 + \left(\frac{d_s}{S}\right)^2 m^2} \quad (3)$$

$$d_c = \sqrt{(l_j - l_i)^2 + (a_j - a_i)^2 + (b_j - b_i)^2} \quad (4)$$

$$d_s = \sqrt{(x_j - x_i)^2 + (y_j - y_i)^2} \quad (5)$$

Onde D é a distância calculada pelo algoritmo; d_c , a distância no espaço de cor CIELAB; d_s , a distância no espaço; S , o espaçamento da grade regular; l , a e b são as componentes do espaço de cor CIELAB; x e y correspondem à posição do pixel; e m à compacidade. A Equação 3 pode ser adaptada para imagens em escala de cinza alterando d_c : desconsidera-se as componentes a e b , e mantém apenas a componente intensidade (l).

Quanto ao parâmetro m , a compacidade é uma medida de peso para a distância no espaço, possibilitando flexibilizar a forma dos segmentos. Se m for um valor baixo, a proximidade de cor terá mais importância, assim, os superpixels serão mais irregulares. Caso contrário, se m for um valor alto, a proximidade de espaço terá maior peso, logo, os superpixels serão mais regulares e rígidos.

2.4.1.3 Watershed

O algoritmo Watershed, baseado na morfologia matemática, foi proposto para a aplicação em imagens por Beucher e Lantuejoul (1979). A palavra em inglês watershed significa linha divisória de águas, segmentos naturais da paisagem, que representa o ponto de máxima da superfície (altura), e vale, o ponto de mínima. Desse modo, a linha divisória e o vale formam uma bacia hidrográfica. O método utiliza esse contexto para tratar as imagens como relevos topográficos (KORNILOV; SAFONOV, 2018). Cada pixel é associado a uma altitude proporcional a sua intensidade, isto é, o valor do pixel da imagem é compreendido como a altura da superfície acima do plano. A forma mais usual para criar o relevo topográfico é utilizar o gradiente da imagem como função de segmentação (MEYER; BEUCHER, 1990).

Existem duas abordagens para o funcionamento do algoritmo: a criação dos watersheds pelo método flooding (inundação) ou rain falling (precipitação) (KORNILOV; SAFONOV, 2018). O primeiro método divide o relevo topográfico em bacias hidrográficas simulando uma inundação a partir dos pontos de mínima, onde a água preenche o ambiente até atingir os pontos de máxima do relevo, que determinam o contorno dos segmentos. O segundo método baseia-se na ideia que uma gota de água escoar até a sua bacia hidrográfica correspondente, no qual o caminho percorrido (escoamento) é chamado de componente conectividade, considerado o percurso mais íngreme entre o ponto de queda, onde a gota atinge a superfície, e o vale. Portanto, todos os componentes conectividade que levam ao mesmo vale formam uma bacia hidrográfica, ou seja, um segmento.

Uma limitação conhecida do algoritmo é a super-segmentação (SCHIEWE, 2002; KORNILOV; SAFONOV, 2018). Isso acontece devido à marcação inicial de todos os pontos de mínima da imagem, que são o centro de cada bacia hidrográfica, entretanto, nem todos eles são igualmente importantes, podendo potencialmente tornarem-se ruídos e afetarem a qualidade da segmentação (KORNILOV; SAFONOV, 2018). Para contornar o problema levantado, pode ser aplicado um filtro de suavização para eliminar detalhes desnecessários (MEYER e BEUCHER, 1990).

2.4.2 Classificação

A classificação consiste em atribuir pixels ou grupo de pixels (objetos) a uma categoria, com a finalidade de representar diferentes alvos de interesse da superfície terrestre (REES, 2012). O processo de classificação de imagens multiespectrais pode ser supervisionado ou não-

supervisionado. Quando supervisionado, deve-se obter previamente um conjunto de treinamento representativo de cada uma das classes temáticas de interesse, para treinar e ajustar o algoritmo de classificação (SCHOWENGERDT, 2006). Além disso, pode ser agrupado em duas categorias: paramétrico e não-paramétrico.

Os algoritmos paramétricos assumem suposições sobre a distribuição de probabilidade para cada classe, enquanto os algoritmos não-paramétricos não fazem qualquer suposição sobre a distribuição de probabilidade. Os algoritmos de aprendizado de máquina são classificadores não-paramétricos, e têm sido amplamente implementados nas classificações de sensoriamento remoto (PAL, 2005; BELGIU; DRAGUT, 2016; MAXWELL et al., 2018; SHEYKHMOUSA et al., 2020).

A classificação supervisionada pode ser dividida em três etapas: extração de atributos, treinamento e a classificação propriamente dita (SCHOWENGERDT, 2006). Assim, nesta seção é abordada a importância da seleção de atributos e como isso pode ser feito; o funcionamento do algoritmo de aprendizado de máquina Random Forest e da validação cruzada k-fold, um método que pode ser utilizado para estimar o desempenho de modelos de predição; e, por fim, apresenta a avaliação da qualidade das classificações por meio da matriz de confusão, que expressa várias métricas.

2.4.2.1 Seleção de Atributos

A seleção de atributos busca reduzir variáveis irrelevantes e redundantes, possibilitando a redução da dimensão do conjunto de dados e possivelmente melhorando os resultados de predição (HALL, 1999; CHANDRASHEKAR; SAHIN, 2014). De acordo com Hall (1999), a seleção de atributos pode ser realizada por meio de dois métodos: filter e wrapper.

Filter seleciona subconjuntos de atributos pelo ranqueamento de importância, levando em conta a capacidade de discernir as classes, para depois aplicá-los em um modelo de predição. Esse método é prático para dados com alta dimensionalidade. Wrapper, por sua vez, avalia vários subconjuntos de atributos por meio de um algoritmo de busca, que procura o subconjunto com o melhor desempenho do modelo de predição.

Correlation-based Feature Selection (CFS) é uma técnica de seleção de atributos do método filter (HALL, 1999), que ranqueia subconjuntos de atributos de acordo com a correlação baseada em uma função heurística de avaliação (Equação 6). Essa medida considera um subconjunto consistente quando contém atributos altamente correlacionados com a classe,

e não correlacionados entre si. A seleção de um atributo depende da sua capacidade de predição dentre os demais.

$$M_S = \frac{k\overline{r_{cf}}}{\sqrt{k + k(k-1)\overline{r_{ff}}}} \quad (6)$$

Onde M_S é o “mérito” heurístico de um subconjunto S contendo k atributos (f); $\overline{r_{cf}}$ é a média da correlação atributo-classe ($f \in S$); $\overline{r_{ff}}$ é a média da correlação entre atributo-atributo. Assim, o numerador da Equação 6 pode ser considerado um indicador do grau de predição do subconjunto de atributos, e o denominador, o grau de redundância entre os atributos (HALL, 1999).

Hall (1999) especifica que a técnica mencionada utiliza três estratégias heurísticas de busca: forward selection, backward elimination e best first, que compreendem a forma como os atributos são designados. Forward selection inicia sem atributos, adicionando-os um por vez, até não obter adições relevantes; backward elimination, por sua vez, começa com todos os atributos e os elimina um a um, enquanto for admissível; por fim, best first pode iniciar com todos ou nenhum atributo, e funciona basicamente da mesma forma, diferenciando-se pela busca mais lenta, a qual é encerrada quando 5 subconjuntos completos consecutivamente são formados e não apresentam mais melhorias diante do atual melhor subconjunto.

2.4.2.2 Aprendizado de Máquina: Random Forest

Aprendizado de máquina, uma das aplicações de inteligência artificial, consiste na capacidade de um sistema aprender a partir de um conjunto de dados, procurando por padrões e aprimorando-se a partir da experiência obtida com o aprendizado (JANIESCH et al., 2021). As técnicas de aprendizado de máquina podem ser supervisionadas, e de acordo com Maxwell et al. (2018), dentre suas diversas aplicações, propicia uma classificação eficiente para dados de sensoriamento remoto. Algumas das vantagens são a capacidade de lidar com dados de alta dimensionalidade e mapear classes com características complexas. (MAXWELL et al., 2018).

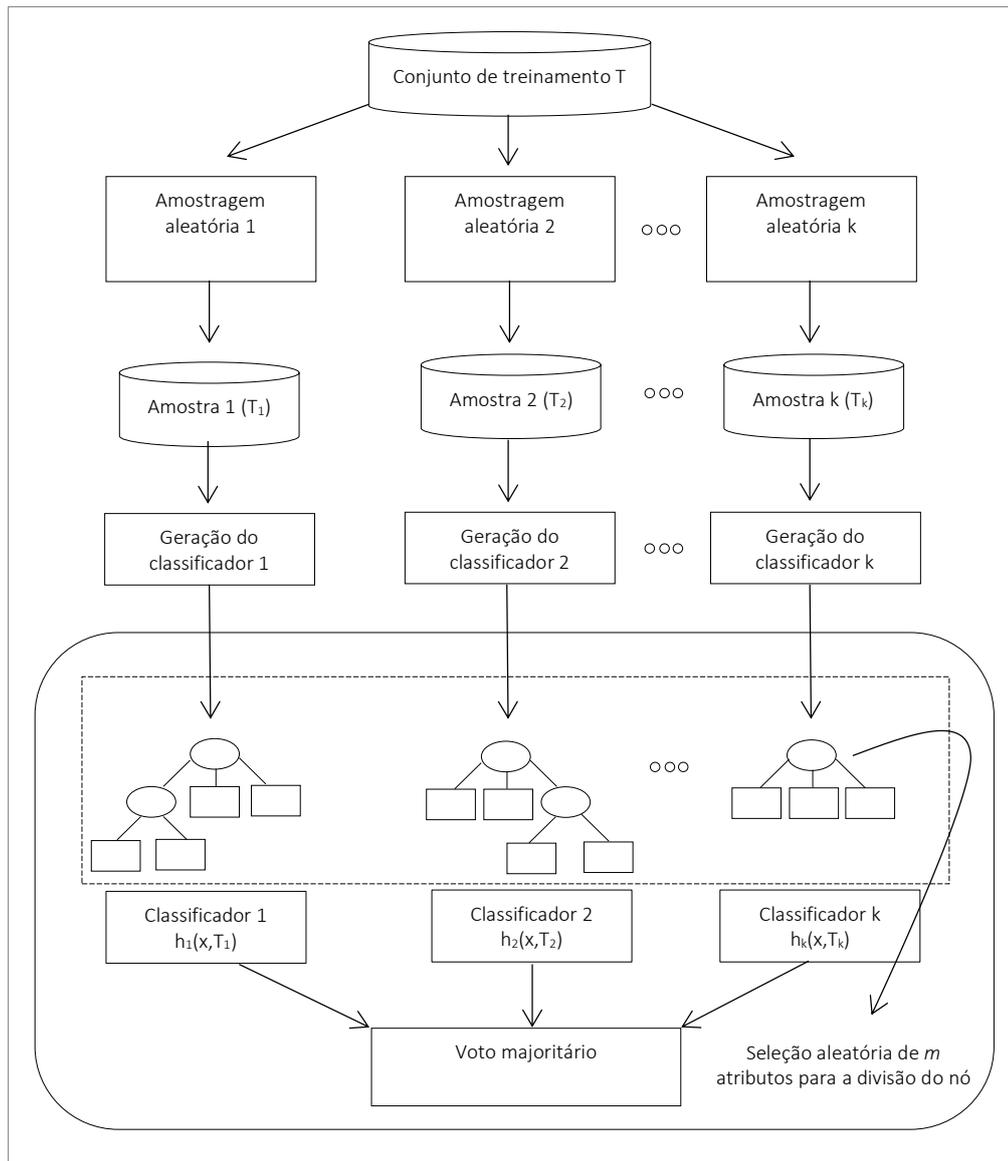
Random Forest é um dos algoritmos de aprendizado de máquina supervisionado, que demonstrou ser consistente para a classificação de dados de sensoriamento remoto (PAL, 2005; BELGIU; DRAGUT, 2016; SHEYKHOUSA et al., 2020). Segundo Maxwell et al. (2018), Random Forest é um algoritmo robusto, que lida bem com grande quantidade de atributos, e

atributos complexos e correlacionados; além da configuração de parâmetros ser considerada fácil, em comparação a outros algoritmos, como, Artificial Neural Network e Support Vector Machines.

O algoritmo Random Forest foi introduzido por Breiman (2001), que consiste em um aprendizado conjunto (ensemble learning), isto é, a combinação de modelos para melhorar o desempenho. Nesse caso, consiste na combinação de árvores de decisão, para classificar dados por meio do voto majoritário (BREIMAN, 2001). O autor define Random Forest como uma coleção de árvores estruturadas, construídas a partir de vetores aleatórios independentes igualmente distribuídos, e que votam para determinar a classe mais popular.

Para construir cada árvore, o conjunto de dados é amostrado aleatoriamente pelo método de bagging para formar subconjuntos de dados de treinamento (vetores aleatórios independentes igualmente distribuídos) do conjunto de dados original, sendo cada subconjunto uma árvore diferente. Bagging (bootstrap aggregation) refere-se a um método de amostragem com reposição, permitindo que elementos possam ser escolhidos mais de uma vez e que outros não sejam escolhidos (BELGIU; DRAGUT, 2016). Cada subconjunto origina uma árvore, em que para cada um de seus nós um subconjunto de m atributos é selecionado aleatoriamente e avaliado. Vale ressaltar que são subconjuntos de m atributos para todos os nós, e o melhor atributo é definido para dividi-lo (OSHIRO, 2013). Após a construção das árvores, cada uma tem poder de voto, e a classe com mais votos é selecionada (OSHIRO, 2013; BELGIU; DRAGUT, 2016). A Figura 6 apresenta o funcionamento esquematizado do algoritmo Random Forest.

Figura 6 - Funcionamento do algoritmo Random Forest.



Fonte: Adaptado de Oshiro (2013)

2.4.2.3 Matriz de Confusão

A matriz de confusão, ou matriz de erro, expressa várias métricas para quantificar a qualidade da classificação (STORY E CONGALTON, 1986; CONGALTON, 2001): acurácia global, acurácia do produtor e acurácia do usuário. A Figura 7 apresenta um exemplo de matriz de confusão para demonstrar como as métricas são calculadas.

Figura 7 - Exemplo de matriz de confusão. V = vegetação;
A = água; AU = área urbana.

		Verdade terrestre			Total linha
		V	A	AU	
Classificação	V	43	10	6	59
	A	3	23	5	31
	AU	2	1	30	33
Total coluna		48	34	41	123

ACURÁCIA GLOBAL
96/123 = 78%

<p>ACURÁCIA DO PRODUTOR</p> <p>V = 43/48 = 90%</p> <p>A = 23/34 = 68%</p> <p>AU = 30/41 = 73%</p>	<p>ACURÁCIA DO USUÁRIO</p> <p>V = 43/59 = 73%</p> <p>A = 23/31 = 74%</p> <p>AU = 30/33 = 91%</p>
--	---

Fonte: Adaptado de Congalton (2001)

De acordo com Story e Congalton (1986), as colunas representam a verdade terrestre (dados de referência) e as linhas, a classificação (dados classificados). A diagonal principal indica a concordância entre os dois conjuntos de dados (número de classificações corretas), cuja soma dos valores de entrada dividindo-se pelo número total de pixels, ou objetos, resulta na acurácia global, uma métrica generalizada da qualidade da classificação. No exemplo dado na Figura 7, a soma da diagonal principal (96), destacada em cinza, é dividida pelo total de pixels (123), obtendo-se uma acurácia global de 78%.

Para estipular a acurácia distribuída entre as classes temáticas, a acurácia do produtor e acurácia do usuário também são derivadas da matriz de confusão. A acurácia do produtor busca saber quão bem uma área da superfície terrestre foi classificada no mapa, dividindo-se o valor de entrada na diagonal principal pelo total da coluna correspondente. Essa métrica informa sobre os erros de omissão, isto é, o que deveria ter sido inserido em uma determinada classe e foi omitido.

A acurácia do usuário, por sua vez, indica a probabilidade de uma amostra classificada no mapa representar de fato a classe temática à que se refere na superfície terrestre, dividindo-se o valor de entrada na diagonal principal pelo total da linha correspondente. O que realmente informa é sobre os erros de comissão, ou seja, o que foi atribuído erroneamente a uma classe específica. Assim, os erros de classificação podem ser tanto de omissão quanto de comissão.

Além disso, o coeficiente Kappa, proposto por Cohen (1960), é outra métrica que pode ser obtida por meio da matriz de confusão, que analisa estatisticamente se o mapa de classificação resultante dos dados de sensoriamento remoto é significativamente melhor do que

um mapa gerado com as classes temáticas atribuídas aos alvos da superfície terrestre de forma aleatória (CONGALTON, 2001). Em suma, avalia a concordância entre os dados de referência e os dados classificados.

De acordo com Richards (2013), deve-se fazer algumas considerações para calcular o coeficiente Kappa: se uma entrada da matriz de confusão for representada como n_{ij} , o número total de pixels como N e o número de classes como M , então a probabilidade de uma classificação estar correta (acurácia global) pode ser expressa pela Equação 7. Ainda, se a soma das linhas e das colunas forem definidas, respectivamente, pela Equação 8 e 9, então é possível descrever o coeficiente Kappa pela Equação 10.

$$p_0 = \frac{1}{N} \sum_{i=1}^M n_{ii} \quad (7)$$

$$n_{+i} = \sum_{k=1}^M n_{ki} \quad (8)$$

$$n_{i+} = \sum_{k=1}^M n_{ik} \quad (9)$$

$$\kappa = \frac{N \sum_{i=1}^M n_{ii} - \sum_{i=1}^M n_{+i} n_{i+}}{N^2 - \sum_{i=1}^M n_{+i} n_{i+}} \quad (10)$$

2.5 Textura em imagem

De acordo com Hay et al. (1996), a textura é considerada uma medida da variação espacial dos tons da imagem. A textura de uma imagem pode ser visualmente percebida em termos de aparência lisa ou rugosa da superfície (IRONS; PETERSEN, 1981; BLASCHKE et al., 2000), sendo muito aplicável na área de sensoriamento remoto (IRONS; PETERSEN, 1981).

A textura é uma característica importante das imagens, e a técnica mais usualmente adotada para extraí-la é pela Grey-Level Co-occurrence Matrix (GLCM), introduzida por Haralick et al. (1973). Os autores definem a informação do pixel como uma função de duas variáveis (x, y) , sendo que a imagem digital é armazenada como uma matriz bidimensional. Se

$L_x = \{1, 2, \dots, N_x\}$ e $L_y = \{1, 2, \dots, N_y\}$ são os domínios espaciais, então $L_x \times L_y$ é a resolução da imagem digital, representada por I , uma função que atribui um tom de cinza $G \in \{1, 2, \dots, N_g\}$ para cada célula de resolução (pixel), em que $I: L_x \times L_y \rightarrow G$. A partir da matriz GLCM é possível extrair várias métricas de textura, como o contraste (Equação 11) e a entropia (Equação 12), em que i é um nível de cinza; j é outro nível de cinza; p_{ij} é a frequência relativa normalizada; e D é a dimensão da matriz GLCM.

$$\text{Contraste} = \sum_{i=0}^{D-1} \sum_{j=0}^{D-1} p_{i,j} \cdot |i - j|^2 \quad (11)$$

$$\text{Entropia} = - \sum_{i=1}^{D-1} \sum_{j=1}^{D-1} p_{ij} \cdot \log p_{ij} \quad (12)$$

Ainda de acordo com os autores, os atributos espectrais descrevem a média das variações de tons de cinza nas várias bandas do espectro eletromagnético, enquanto os atributos de textura contêm informação sobre a distribuição dos tons de cinza de uma banda específica. Para extrair as informações de textura, assume-se que em uma imagem I está contida uma relação espacial geral, ou uma “média”, que os tons de cinza da imagem têm um com o outro.

2.6 Scale Invariant Feature Transform (SIFT)

A técnica Scale Invariant Feature Transform (SIFT) foi desenvolvida por Lowe (1999, 2004). Segundo o autor, o algoritmo é invariante à escala e orientação, e parcialmente invariante a mudanças de iluminação e perspectiva. Ainda, o autor aponta que um aspecto importante da técnica é a geração de uma grande quantidade de pontos que descrevem toda a imagem, o valor obtido depende do conteúdo dela e das escolhas dos parâmetros.

A técnica consiste em quatro etapas principais de computação: detecção de extremos no espaço-escala; localização de pontos-chave; definição da orientação; e descrição dos pontos-chave. Conforme Lowe (1999, 2004) e explicações resumidas de Gonzáles (2010) e Berveglieri e Tomasselli (2017), as quatro etapas do funcionamento do algoritmo serão brevemente descritas a seguir.

2.6.1 Detecção de extremos no espaço-escala

A primeira etapa busca pontos de interesse, denominados pontos-chave, invariantes à escala por meio de características estáveis na imagem. Para isso, utiliza-se a função Diferença Gaussiana $D(x, y, \sigma)$ ou DoG, dada pela Equação 13, sendo que a função Gaussiana $G(x, y, \sigma)$ é expressa pela Equação 14, em que σ é o desvio padrão, nível de suavização.

$$D(x, y, \sigma) = L(x, y, k\sigma) - L(x, y, \sigma) \quad (13)$$

$$G(x, y, \sigma) = \frac{1}{2\pi\sigma^2} e^{-(x^2+y^2/2\sigma^2)} \quad (14)$$

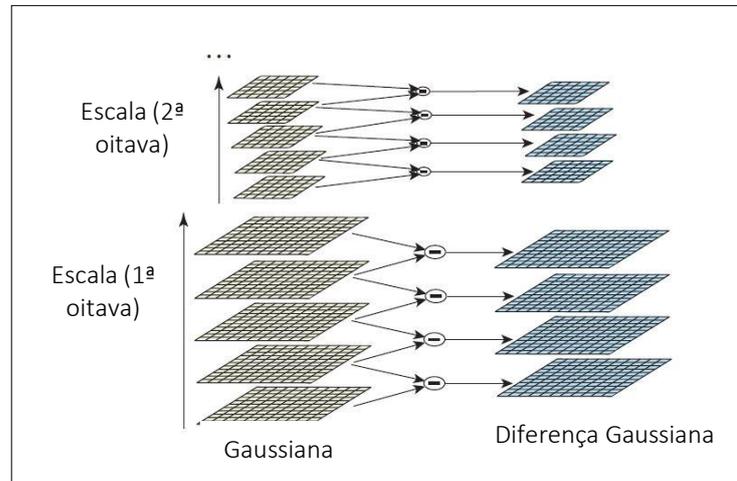
Primeiramente, é aplicado o filtro de suavização Gaussiano $G(x,y,\sigma)$ em uma dada imagem de entrada $I(x,y)$, gerando-se imagens suavizadas $L(x,y,\sigma)$, conforme a Equação 15. As novas imagens geradas são subtraídas duas a duas, de forma adjacente, (Equação 13), separadas por uma constante k .

$$L(x, y, \sigma) = G(x, y, \sigma) * I(x, y) \quad (15)$$

O conjunto de todas as imagens filtradas e subtraídas (DoG) forma uma oitava. A cada nova oitava, a imagem de entrada é redimensionada para a metade de seu tamanho em relação ao processamento da oitava anterior, diminuindo o nível de detalhamento espacial da imagem. A quantidade de oitavas é variável, depende da necessidade de cada aplicação (LOWE, 2004). O autor ilustra a construção da pirâmide de imagens na Figura 8.

A aplicação do filtro Gaussiano permite simular diferentes níveis de detalhe, assemelhando-se a mudanças de escala. Os pontos candidatos a pontos-chave são as posições de máximos e mínimos locais selecionados a partir de cada DoG, comparando-se cada pixel com seus vizinhos na própria imagem e nas DoGs adjacentes.

Figura 8 - Uma oitava é composta por imagens gaussianas (filtradas), que são subtraídas duas a duas, de forma adjacente, na mesma escala, obtendo-se as imagens-diferença. A oitava seguinte redimensiona a imagem original pela metade do seu tamanho.



Fonte: Adaptado de Lowe (2004)

2.6.2 Localização de pontos-chave

A primeira etapa seleciona pontos candidatos a serem pontos-chave, mas é necessário eliminar pontos com baixo contraste (sensíveis a ruídos) ou mal localizados ao longo de bordas, o que leva à segunda etapa, a qual realiza uma filtragem nos pontos candidatos. O ajuste é feito com uma função quadrática 3D do ponto para determinar a posição de máximo local a partir de uma interpolação. Para tal, utiliza-se a expansão de Taylor da função DoG até segunda ordem, que dará o máximo local.

A função DoG apresenta forte resposta nas bordas e, por isso, deve-se calcular a matriz Hessiana (H) 2x2 com base na razão das curvaturas principais, no local e escala do ponto-chave. Verifica-se se o raio das curvaturas principais está abaixo de um limiar r , Equação 16, sendo que $Tr(H)$ é o traço de H e $Det(H)$ o determinante de H . O ponto-chave é admitido se a razão das curvaturas estiver dentro do limiar.

$$\frac{Tr(H)^2}{Det(H)} < \frac{(r + 1)^2}{r} \quad (16)$$

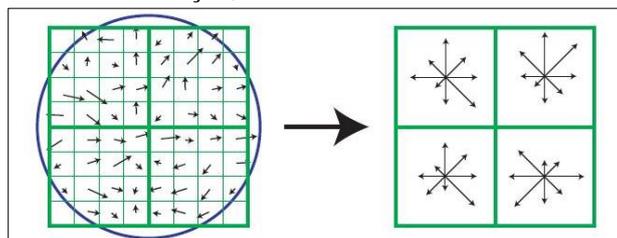
2.6.3 Definição da orientação

A terceira etapa consiste em ajustar o ponto-chave em relação à orientação, utilizada na etapa seguinte para construir os descritores invariantes à orientação. Para cada ponto-chave, são calculados os gradientes ao seu redor, dados por magnitude $m(x,y)$ e orientação local $\theta(x,y)$. A partir disso, é possível gerar um histograma de orientação com os pixels vizinhos, indicando as direções dominantes (picos) dos gradientes locais. Todas as direções acima de 80% em relação ao valor máximo, também são considerados na orientação do ponto-chave. Sendo assim, pode-se criar vários pontos-chaves na mesma localização, com orientações distintas.

2.6.4 Descrição dos pontos-chave

A quarta e última etapa consiste em obter os descritores de cada ponto-chave. Para garantir a propriedade de invariância à orientação, as orientações dos gradientes dos descritores são direcionadas para a orientação do ponto-chave. A vizinhança de cada um deles é determinada por $n \times n$ regiões e $k \times k$ pixels. A Figura 9 mostra o exemplo de 4×4 sub-regiões com 8 valores de orientação, gerando um vetor de 128 valores para cada ponto-chave. O vetor com 128 valores são as características numéricas que representam o entorno do ponto-chave, logo, descrevem a textura local.

Figura 9 - Construção do descritor para um ponto-chave, determinado por uma vizinhança de 4×4 sub-regiões e 8 valores e orientação, obtendo um vetor de 128 valores.



Fonte: Adaptado de Lowe (2004)

3 MATERIAIS E MÉTODOS

São apresentados nesta seção a área de estudo, os dispositivos e ferramentas computacionais, bem como o método proposto para a classificação de espécies de VAE, usando imagens aéreas e algoritmos de segmentação e aprendizado de máquina.

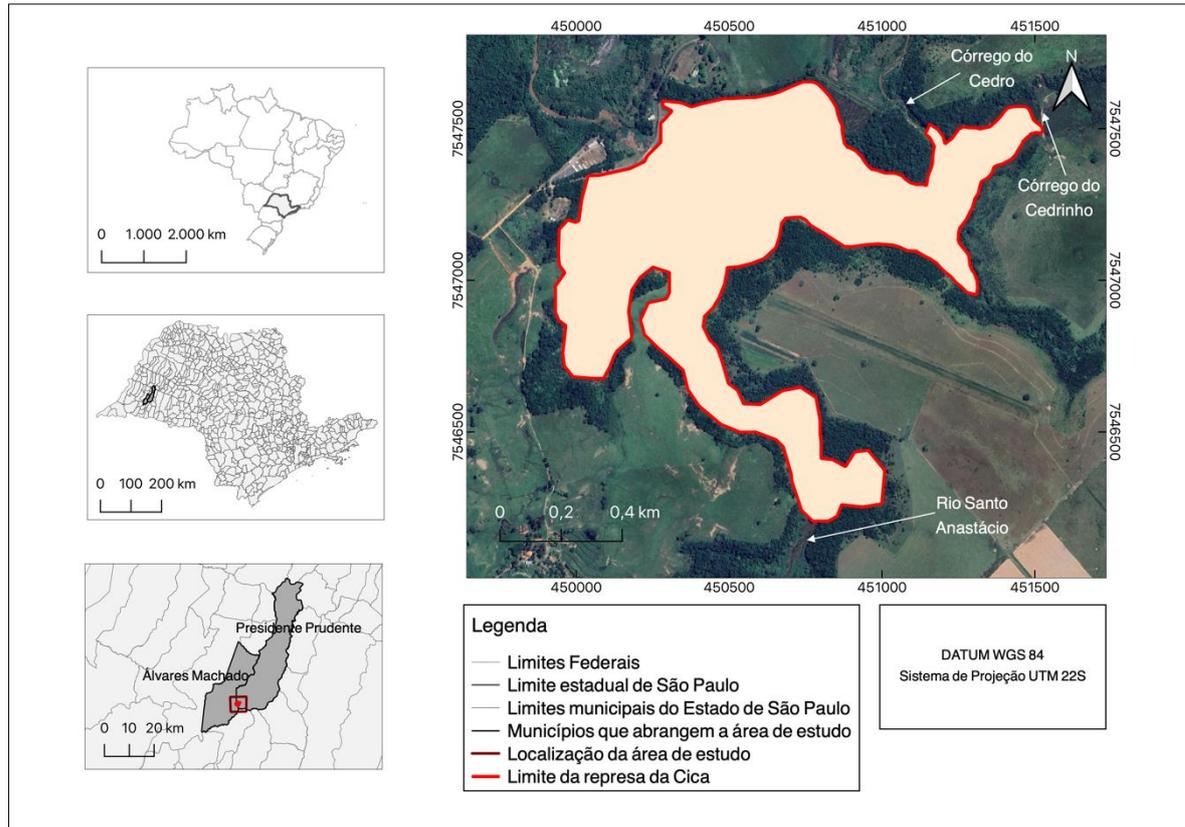
3.1 Área de estudo

O estudo foi realizado em parceria com o projeto aprovado PIPE – fase 2 nº 2021/03110-8, da empresa Inspectral Soluções Inovadoras em Tecnologia da Informação Espacial Ltda, no reservatório de abastecimento público do município de Presidente Prudente, no Estado de São Paulo. O reservatório, popularmente conhecido como represa da Cica, está localizado na bacia hidrográfica do manancial do alto curso do Rio Santo Anastácio (DIBIESO, 2013), na confluência do Córrego do Cedro e do Cedrinho.

De acordo com Dibieso (2013), a represa da Cica corresponde a uma área de 0,67 km² e 6,80 km de perímetro, onde é realizada a captação de água superficial pela Companhia de Saneamento Básico do Estado de São Paulo (Sabesp), aproximadamente 30% do abastecimento público de água do município de Presidente Prudente (DIBIESO, 2013; HATSUMURA, 2018). A Figura 10 apresenta a área de estudo, situada entre os municípios de Álvares Machado e Presidente Prudente, no Estado de São Paulo.

O reservatório está inserido no contexto de um trecho urbano e apresenta vários aspectos ambientais. Dibieso (2013) elencou os principais, sendo eles: desenvolvimento de processos erosivos; deposição irregular de resíduos sólidos e líquidos; e a supressão da vegetação nativa nas Áreas de Preservação Permanente (APPs). Além disso, nas proximidades da represa, encontram-se o Curtume Vitappeli, as rodovias Júlio Budisk, Raposo Tavares e Assis Chateaubriand, onde está localizado o Aeroporto Estadual de Presidente Prudente (DIBIESO, 2013; HATSUMURA, 2018). Os aspectos ambientais apontados podem ser responsáveis, direta ou indiretamente, pelo descontrole no crescimento de VAE em reservatórios (POMPÊO, 2017), como, no caso da represa da Cica.

Figura 10 - Localização da represa da Cica, situada entre os municípios de Álvares Machado e Presidente Prudente, no Estado de São Paulo.



3.2 Materiais

Neste estudo, os principais dispositivos utilizados para a aquisição das imagens foram a câmara multiespectral, modelo Sony Alpha 6000 com sensor de sistema dual (Figura 11), desenvolvida pela Agrowing; o receptor GNSS (Global Navigation Satellite System), modelo Reach M+ (Figura 12), fabricado pela Emlid; e o hexacóptero (VARP), modelo X800 GEO, da XFly Tecnologia (Figura 13).

Quanto ao processamento, as seguintes ferramentas computacionais foram utilizadas:

- Software Agisoft Metashape – processamento fotogramétrico para a obtenção de ortomosaicos;
- Software QGIS 3.20.3-Odense – segmentação, aplicação de filtro de suavização, extração dos índices de vegetação, seleção das amostras de treinamento e validação, e geração de mapas de classificação;
- Software Spring 5.5.6 – segmentação;
- Software TerraView 5.6.1 – extração dos atributos dos pixels a partir da ferramenta Geographical Data Mining Analyst (GeoDMA);

- Linguagem Python – uso das bibliotecas para tarefas diversas: subamostragem, segmentação, extração dos descritores de textura SIFT, cálculo de média, mediana e coeficiente de variação;
- Software Microsoft Excel – organização dos dados;
- Software WEKA 3.8.5 – seleção de atributos e classificação.

3.2.1 Câmara multiespectral

A câmara multiespectral utilizada, modelo Alpha 6000, foi desenvolvida pela Agrowing (Figura 11). O sistema de lentes possui um conjunto de duas cabeças com diferentes filtros para produzir 4 bandas espectrais para NDVI (TOMMASELLI et al., 2020). A Tabela 1 apresenta as especificações do sensor.

Figura 11 - Câmara multiespectral, modelo Alpha 6000, com o sensor de sistema de duas cabeças.



Fonte: Agrowing (2023)

Tabela 1 - Especificações do sensor de sistema de duas cabeças, modelo Alpha 6000.

Parâmetro	Especificação
Tipo	Montagem única com duas lentes
Campo de visada	Diagonal 45,90°
	Horizontal 35,0°
	Vertical 26,60°
Distorção das lentes	1%
Bandas multiespectrais para NDVI	450; 550; 650; 850 nm
Distância focal	25 mm
Abertura	Fixo F6
Dimensões	60 x 35,2 mm
Peso das lentes	150 g
Peso total do sensor incluindo a bateria	580 g

Fonte: Adaptado de Agrowing (2023)

3.2.2 Receptor GNSS

O receptor GNSS (Figura 12) é de frequência simples (L1), modelo Reach M+, fabricado pela Emlid. O aparelho é responsável por obter dados de localização com precisão de 50 cm ou menos, sendo que o posicionamento GNSS pode ser realizado por PPK (Post Processed Kinematic) com linha de base até 20 km ou RTK (Real Time Kinematic) até 10 km. A Tabela 2 fornece as demais informações sobre o dispositivo.

Figura 12 - Receptor GNSS Reach M+.



Fonte: Emlid Brasil (2023)

Tabela 2 - Especificações do receptor GNSS Reach M+.

Parâmetro	Especificação
Dimensões	56,4 x 45,3 x 14,6 mm
Peso	20 g
Sinais rastreados	GPS/QZSS L1; GLONASS G1; BeiDou B1; Galileo E1; SBAS
Canais	72
Taxa de atualização	14 Hz / 5 Hz
IMU	9DOF
Posicionamento	
Estático horizontal	5 mm + 1 ppm
Estático vertical	10 mm + 2 ppm
Cinemático horizontal	7 mm + 1 ppm
Cinemático vertical	14 mm + 2 ppm

Fonte: Adaptado de Emlid Brasil (2023)

3.2.3 Veículo Aéreo Remotamente Pilotado (VARP)

O hexacóptero X800 GEO (Figura 13), desenvolvido pela XFly Tecnologia, pode ser pilotado manualmente e/ou voar de forma autônoma por meio da controladora de voo Pixhawk com GPS, que é indispensável para realizar voos autônomos, pois permite seguir a rota pré-programada e corrigi-la, se necessário. Dessa forma, o veículo pode deslocar-se com velocidade

máxima de 60 km/h e transportar carga até 1,5 kg. As especificações adicionais estão descritas na Tabela 3.

Figura 13 - VARP X800 GEO.



Fonte: XFly Tecnologia (2023)

Tabela 3 - Especificações do VARP X800 GEO.

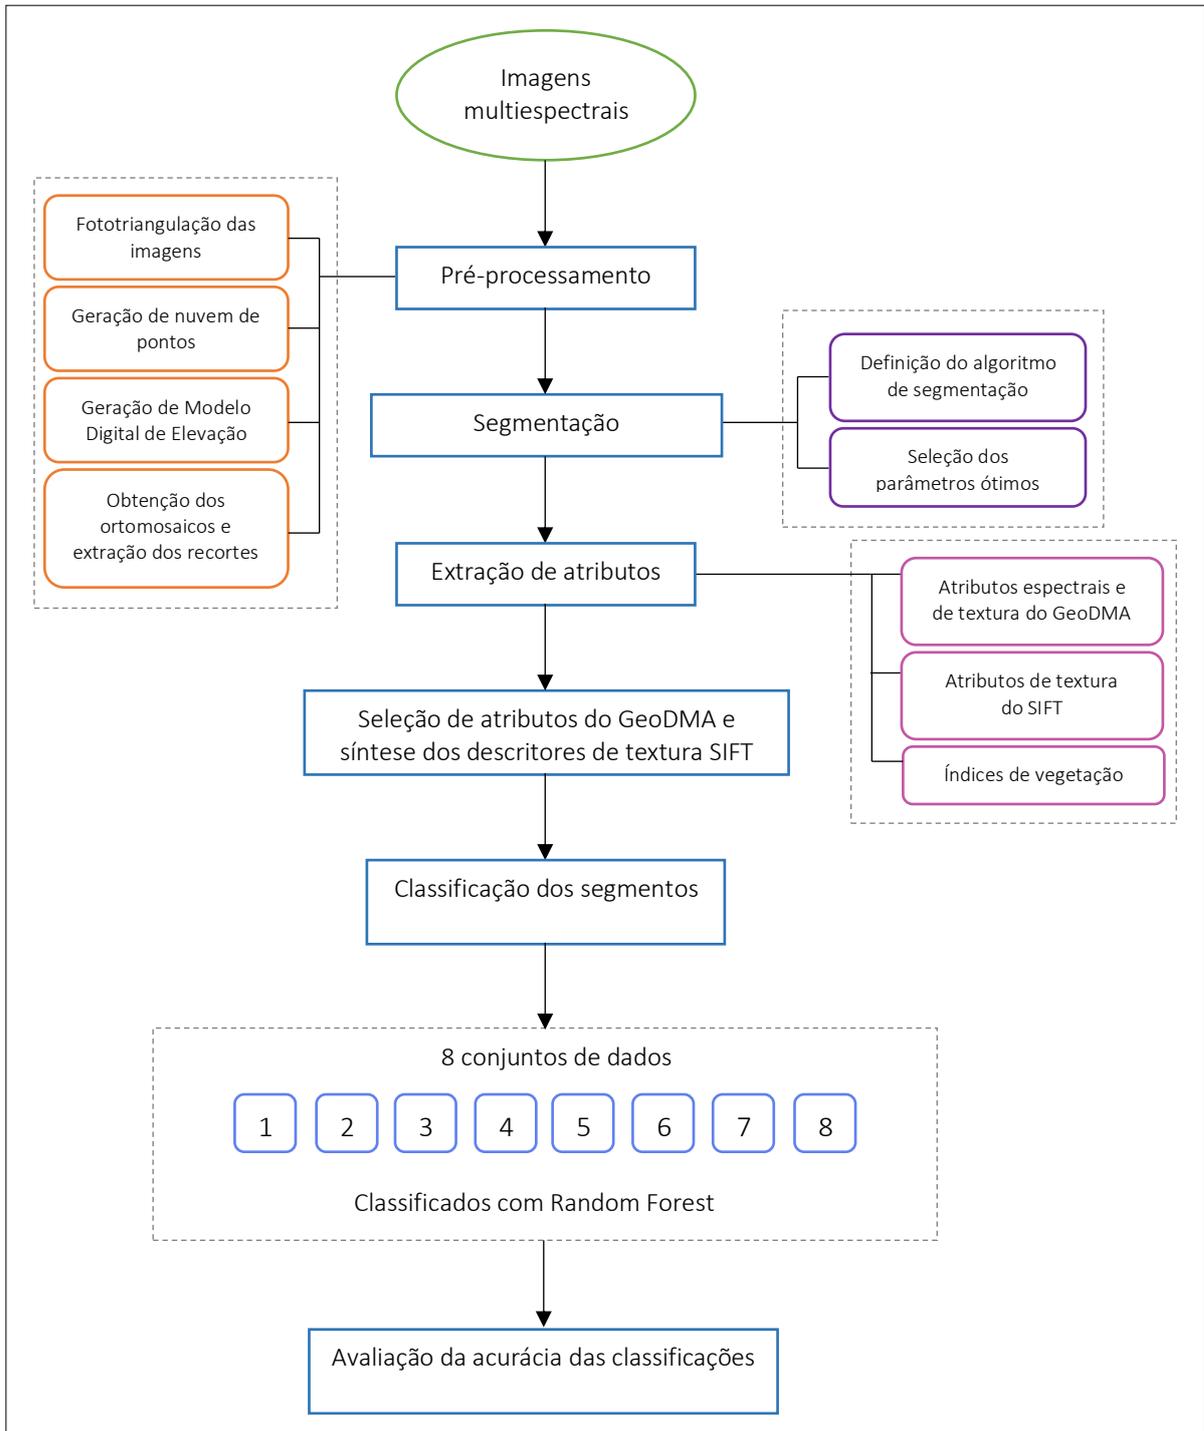
Parâmetro	Especificação
Área necessária para decolagem	Círculo com 1 m de raio
Peso total de decolagem já com câmara	5 kg
Distância entre eixos	800 mm
Circunferência total	1200 mm
Alimentação	1 bateria 16000 mAh – 6S
Tempo de preparação para decolagem	10 minutos (com programação de voo)

Fonte: Adaptado de XFly Tecnologia (2023)

3.3 Método

O método usa imagens multiespectrais obtidas por VARP para classificar VAE pela abordagem OBIA com o algoritmo Random Forest, empregando atributos de textura. Este estudo inclui as seguintes etapas principais: (1) seleção do algoritmo de segmentação e definição dos parâmetros ótimos; (2) segmentação de imagens; (3) extração e seleção/síntese dos atributos espectrais e de textura; (4) classificação de 8 composições diferentes de atributos (8 conjuntos de dados); (5) avaliação da acurácia das classificações. A Figura 14 apresenta o fluxograma das etapas do método proposto.

Figura 14 - Fluxograma das etapas do método proposto neste estudo.



3.3.1 Aquisição de imagens e processamento fotogramétrico para a obtenção de ortomosaicos

As imagens foram adquiridas no dia 26 de março de 2021 com a câmara multiespectral e o receptor GNSS embarcados no VARP. A utilização de GNSS deve-se à dificuldade de se

obter tie points² em água, bem como para obter a posição de cada uma das imagens adquiridas pelo sensor embarcado no VARP. As imagens foram obtidas em 4 bandas espectrais: azul, verde, vermelho e IVP nas configurações do NDVI, conforme as especificações de voo autorizadas pelo Departamento de Controle do Espaço Aéreo (DECEA), e planejadas para fazer o levantamento de uma parcela do reservatório contendo VAE, como indicado na Figura 15. É relevante destacar que as condições apresentadas do reservatório não necessariamente representam as condições do dia do levantamento de campo. A Tabela 4 especifica os parâmetros da aquisição das imagens.

Figura 15 - Indicação da área de voo realizado na represa da Cica, de uma parcela do reservatório contendo VAE.



Tabela 4 - Especificações dos parâmetros da aquisição das imagens.

Parâmetro	Especificação
Altura de voo	50 m
Velocidade de deslocamento	5 m/s
Tamanho do pixel no terreno (<i>Ground Sample Distance - GSD</i>)	0,78 cm
Intervalo entre fotos	1 s

² Tie points (pontos homólogos ou pontos de amarração) são pontos visualmente reconhecíveis em uma área de sobreposição entre uma ou mais imagens.

As imagens adquiridas tiveram suas bandas corrigidas, para então serem fototrianguladas a fim de compor o bloco de imagens mediante o ajustamento por feixe de raios no software Agisoft Metashape. Nessa etapa, os parâmetros de orientação interior (POI) e exterior (POE) são determinados com base nos POEs iniciais, permitindo gerar um ortomosaico. Sendo assim, foram configurados três projetos fotogramétricos com blocos de imagens diferentes, correspondendo a áreas do reservatório contendo VAE. Para cada bloco, as imagens foram alinhadas com o intuito de encontrar os tie points e gerar uma nuvem densa de pontos por meio da intersecção dos pontos fotogramétricos no espaço 3D e, em seguida obter o Modelo Digital de Elevação (MDE), o que permitiu produzir três ortomosaicos de alta resolução espacial (0,8 cm). Vale elucidar que os valores dos pixels foram utilizados diretamente das imagens, sem nenhum tipo de correção radiométrica.

3.3.2 Extração de recortes a partir dos ortomosaicos

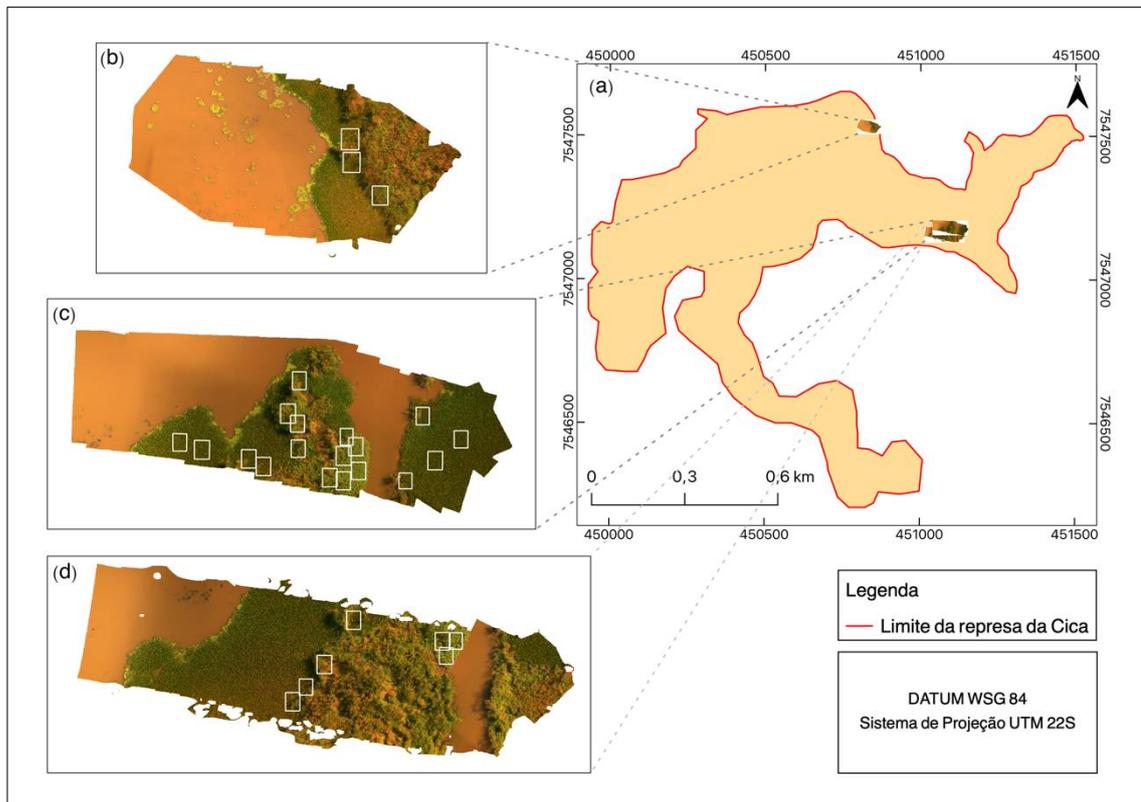
A partir dos ortomosaicos, foram extraídos 28 recortes (retângulos) contendo espécies de VAE, cada recorte possui em média 450 pixels de largura e 600 pixels de altura, alguns com presença de uma única espécie (12 recortes), outros com mistura entre espécies (16 recortes). Levando em consideração a alta resolução espacial, a finalidade foi recortar apenas regiões com VAE, sem a presença da superfície d'água, para fazer as análises de forma minuciosa e controlada. Os três ortomosaicos obtidos constam na Figura 16. Visualmente 2 e 3 parecem se sobrepor, no entanto, são áreas contíguas. Todas as figuras dos ortomosaicos e recortes apresentados neste estudo estão na composição cor verdadeira, sendo as bandas 1, 2 e 3 atribuídas, respectivamente, às cores azul, verde e vermelho.

Visualmente foram identificadas três espécies de VAE na área imageada do reservatório: aguapé (*Eichhornia crassipes*), erva-de-jacaré (*Alternanthera philoxeroides*) e taboa (*Thypha domingensis*). A Figura 16 destaca os recortes de cada ortomosaico, os quais foram selecionados, levando em consideração as três espécies. Para cada uma delas, há 4 recortes diferentes contendo apenas a espécie de VAE especificada (sem misturar com as outras duas espécies), que somam os 12 recortes mencionados. Os outros 16 recortes contemplam a mistura entre as três espécies, sendo que, na parcela imageada do reservatório, a maior ocorrência é de aguapé, e a menor, erva-de-jacaré.

Os ortomosaicos gerados são de áreas que apresentam pelo menos duas espécies diferentes, e somente nos ortomosaicos 2 e 3 encontra-se a espécie erva-de-jacaré, pois não foi

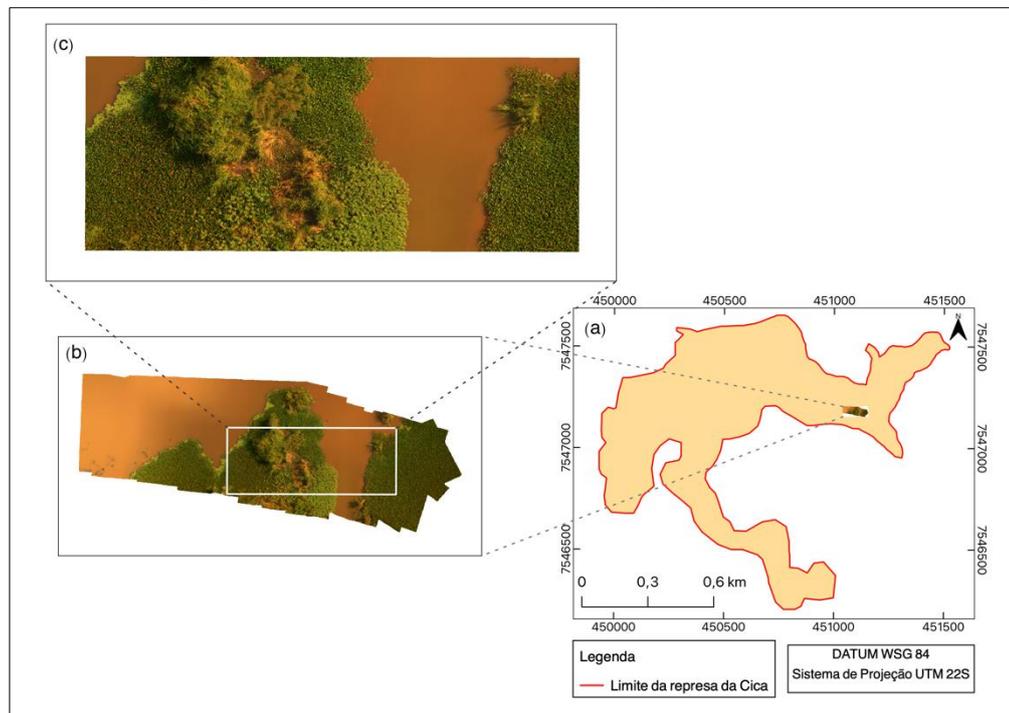
localizada nas outras áreas imageadas do reservatório. Esse fator limitou a obtenção de outros ortomosaicos e recortes, pois as classes temáticas ficariam muito desbalanceadas, por isso alguns recortes se sobrepõem (sobreposição inferior a 15%).

Figura 16 - (a) Localização dos três ortomosaicos no contexto da represa da Cica. Ortomosaicos (b) 1, (c) 2 e (d) 3, destacando os recortes (retângulos) extraídos.



Posteriormente, todos os processamentos descritos, que contemplam os 28 recortes, também foram replicados em uma área teste (Figura 17), pertencente ao ortomosaico 2. Esse recorte abrangeu uma região com a ocorrência das três espécies e incluindo a superfície d'água. O intuito foi facilitar a elaboração de mapas de classificação, favorecendo a visualização da aplicação do método proposto, visto que os recortes são esparsos.

Figura 17 - Localização do ortomosaico 2 no contexto da represa da Cica; (b) Ortomosaico 2 destacando o recorte de (c) uma área, denominada área teste, com a presença das três espécies de VAE e superfície d'água.



3.3.3 Segmentação: Seleção do algoritmo de segmentação

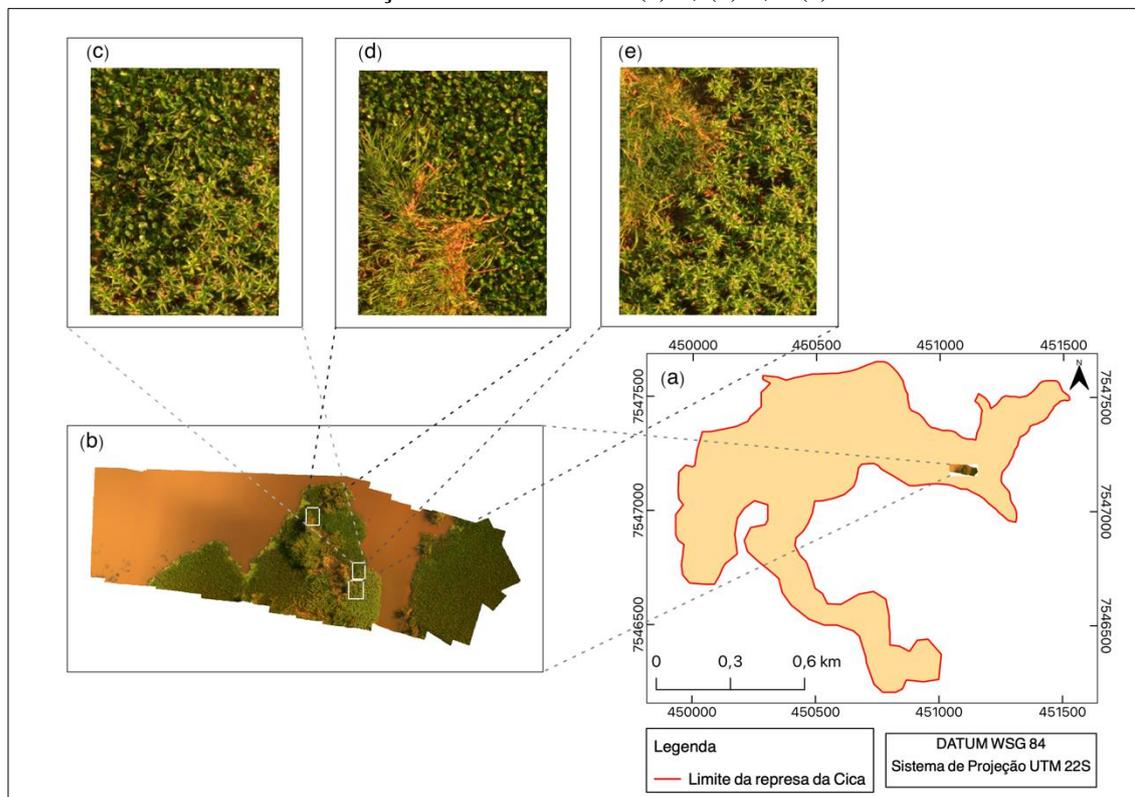
A segmentação tem como finalidade dividir as regiões com VAE em sub-regiões homogêneas. Neste estudo, não houve interesse em segmentar cada espécie como uma única região, visto que a abordagem de classificação deve utilizar os atributos de cada segmento (sub-região) para realizar a análise e atribuir a uma classe. Ao final, as sub-regiões rotuladas com a mesma classe e que estavam contíguas entre si formaram regiões contínuas. Portanto, o critério de seleção do algoritmo consiste na capacidade de segmentar em sub-regiões que abrangem o contexto de uma mesma espécie de VAE, sem contornar individualmente detalhes, como, folhas, sombras e espaçamento entre as plantas.

O alto nível de detalhamento da cena em imagens de alta resolução espacial pode ser compreendido como ruído para alguns algoritmos de segmentação, causando o efeito da super-segmentação, isto é, a delimitação de muitos segmentos que não correspondem ao que é esperado visualmente. Por outro lado, a falta de detalhamento pode causar a sub-segmentação, gerando segmentos insuficientes. Desse modo, foi considerado relevante explorar o comportamento de três algoritmos de segmentação, a fim de encontrar o mais apropriado entre eles e o grau de detalhe mais propício para segmentar em regiões que possuam o significado de

interesse: um objeto (sub-região) representativo das variações espectrais e de textura da cobertura de uma mesma espécie de VAE.

Para tanto, dos 28 recortes, foram selecionados três do ortomosaico 2 (Figura 18b), como especificado na Figura 18, os quais foram subamostrados e suavizados em diferentes níveis, com a finalidade de simular níveis variados de detalhamento da cena. O recorte 1 (Figura 18c) contém duas espécies; o recorte 2 (Figura 18d) abrange duas espécies, repetindo uma das espécies do recorte 1; e o recorte 3 (Figura 18e) apresenta uma espécie do recorte 1 e outra espécie do recorte 2. Portanto, cada recorte possui duas espécies de VAE para serem separadas.

Figura 18 - (a) Localização do ortomosaico 2 no contexto da represa da Cica, com a localização dos três recortes: (c) 1, (d) 2, e (e) 3.



As imagens foram subamostradas por meio da biblioteca Python *gdal* 3.3.2 (GDAL/OGR, 2023) pelo método bilinear, devido ao aspecto visual mais suave, sem as discontinuidades geométricas do vizinho-mais-próximo, e computacionalmente mais rápido que a convolução cúbica (ARIF; AKBAR, 2005). A interpolação bilinear calcula o novo valor de pixel pela média ponderada dos quatro pixels vizinhos mais próximos (ARIF; AKBAR, 2005; TELLES JUNIOR, 2008). Os três recortes foram subamostrados do nível original (0,8 cm) para: 1 cm; 1,6 cm; 2 cm; e 3 cm.

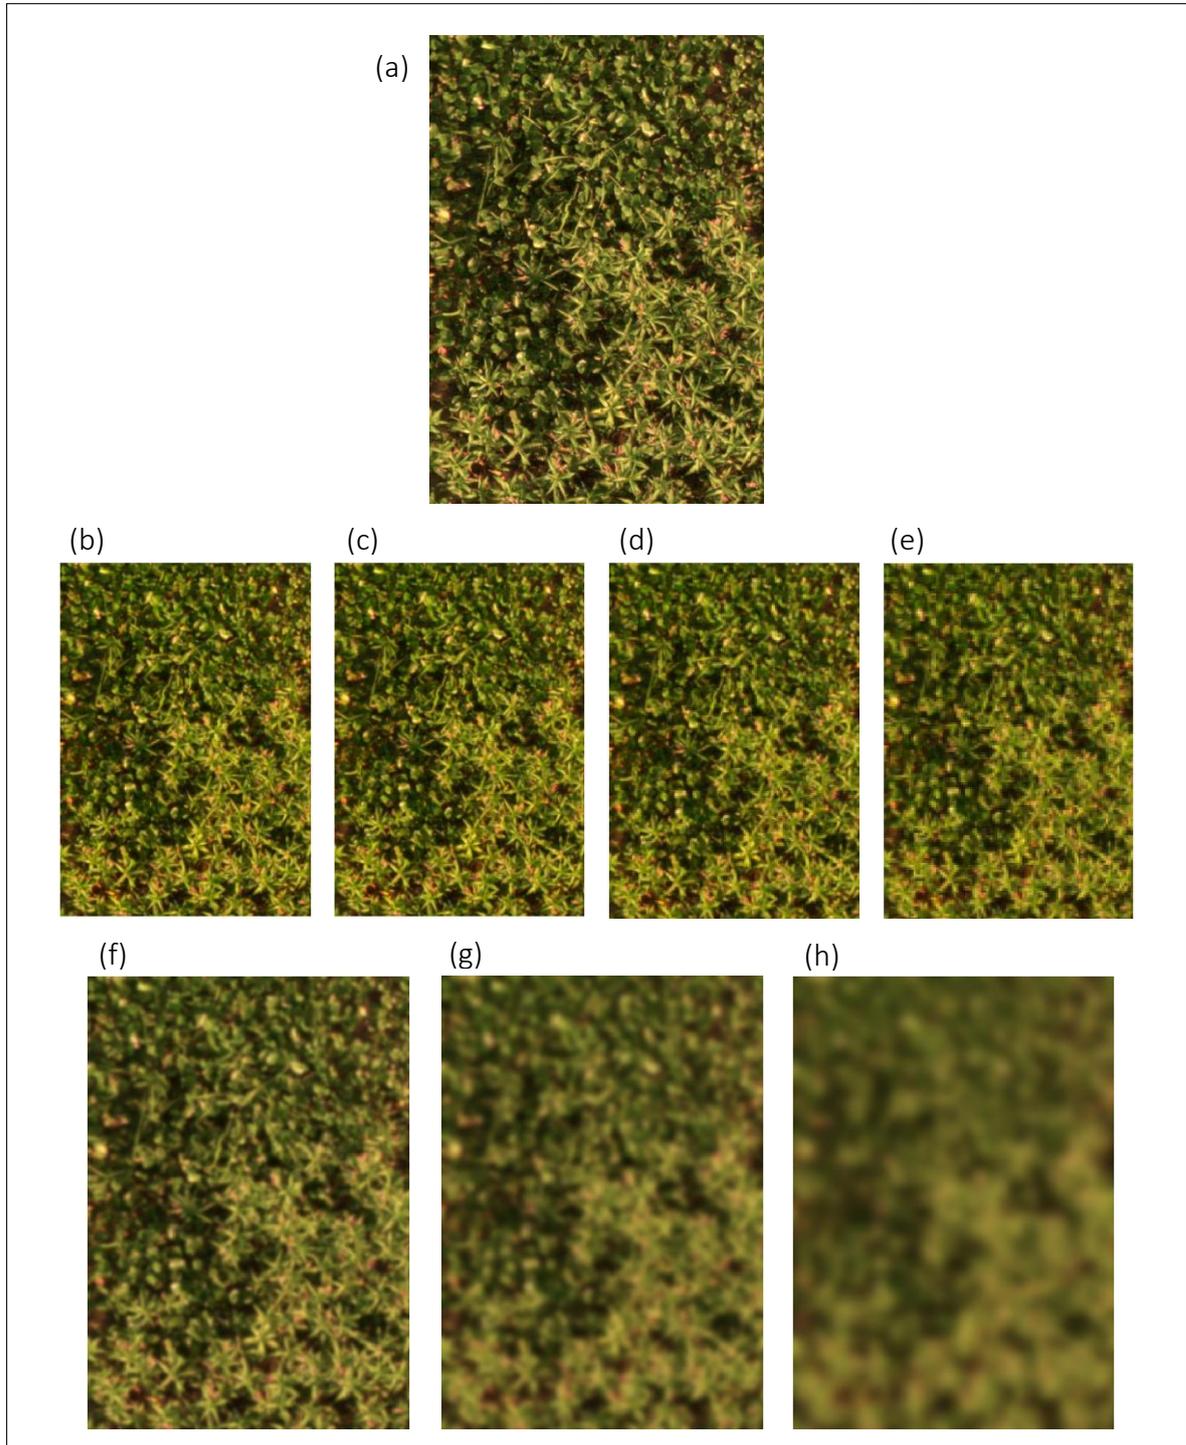
Quanto à suavização, as imagens foram suavizadas utilizando o filtro gaussiano, dada a sua característica de não somente reduzir ruídos, mas efetivamente borrar ou desfocar a imagem (KUMAR; SODHI, 2020), por meio da biblioteca Python *scikit-image* 0.18.3 (VAN DER WALT et al., 2014). O filtro gaussiano é descrito pela Equação 17, onde i refere-se ao eixo horizontal; j , ao eixo vertical; e σ é o parâmetro de largura ou desvio-padrão, no qual quanto maior o seu valor, maior o grau de suavização (WANG et al., 2014). Os três recortes foram suavizados com $\sigma = 2, 4$ e 8 .

$$g[i, j] = e^{-\frac{i^2+j^2}{2\sigma^2}} \quad (17)$$

As resoluções espaciais da subamostragem e os desvios padrões da suavização foram definidos e incrementados empiricamente. A fim de ilustrar a aparência dos recortes após processados, a Figura 19 mostra o recorte 1 (Figura 19a) subamostrado (Figuras 19b-e) e suavizado (Figuras 19f-h) nos diferentes níveis. Nota-se que o aspecto visual é distinto entre as duas abordagens. A subamostragem causa a perda da resolução das imagens, deixando os detalhes com menos nitidez. A suavização, por sua vez, causa o desfoque das imagens, eliminando o alto nível de detalhamento, que é compreendido como ruído pelo filtro gaussiano.

Três algoritmos de segmentação foram testados nos três recortes: Crescimento de Regiões, Superpixel e Watershed. O algoritmo Crescimento de Regiões foi aplicado no software Spring 5.5.6, em que se definem dois parâmetros: limiar de similaridade e limiar de área; o algoritmo Superpixel foi aplicado com a biblioteca Python *scikit-image* 0.18.3 (VAN DER WALT et al., 2014), que exige apenas a definição do parâmetro k ; e o algoritmo Watershed foi aplicado no software QGIS 3.20.3-Odense, com a biblioteca Orfeo ToolBox (OTB) 7.3.0 (INGLADA; CHRISTOPHE, 2009), onde deve-se configurar depth threshold (limite de profundidade máxima) e flood level (nível de inundação). Dentre os três, o algoritmo Superpixel se sobressaiu neste estudo, pois apresentou facilidade na definição dos parâmetros que, uma vez definidos, puderam ser utilizados para todos os recortes e gerar resultados consistentes.

Figura 19 - (a) Recorte 1 no nível original (0,8 cm). Subamostragem do recorte 1 para: (b) 1 cm; (c) 1,6 cm; (d) 2 cm; (e) 3 cm. Suavização do recorte 1 para: (f) $\sigma=2$; (g) $\sigma=4$; (h) $\sigma=8$.



3.3.4 Segmentação: Avaliação da acurácia da segmentação

Após selecionado o algoritmo Superpixel, foi necessário avaliar a abordagem e os níveis mais adequados de subamostragem e/ou suavização. Experimentalmente, concluiu-se que as duas abordagens, combinadas, proporcionaram um resultado melhor na segmentação dos

recortes, com três combinações de níveis de subamostragem e suavização: (1) 1,6 cm + $\sigma = 6$ (Segmentação 1); (2) 2 cm + $\sigma = 6$ (Segmentação 2); e (3) 3 cm + $\sigma = 4$ (Segmentação 3). As três segmentações foram replicadas em todos os 28 recortes. Visto que ficaram bem similares e difíceis visualmente de serem distinguidas, foi realizada a avaliação da acurácia das segmentações para selecionar apenas uma dentre as três combinações.

De acordo com Costa (2018), não há um método padronizado para a avaliação da acurácia da segmentação de imagens. Para este caso, foi utilizada a métrica Precision (VAN RIJSBERGEN, 1979; ZHANG et al., 2015) ou Precisão (Equação 18), a qual, segundo os autores, descreve a qualidade dos segmentos. Sendo n o número de segmentos; S_i o segmento em análise; e R_i o polígono de referência em análise, isto é, o polígono criado manualmente para ser comparado ao segmento gerado, por meio da área de sobreposição entre os dois (\cap).

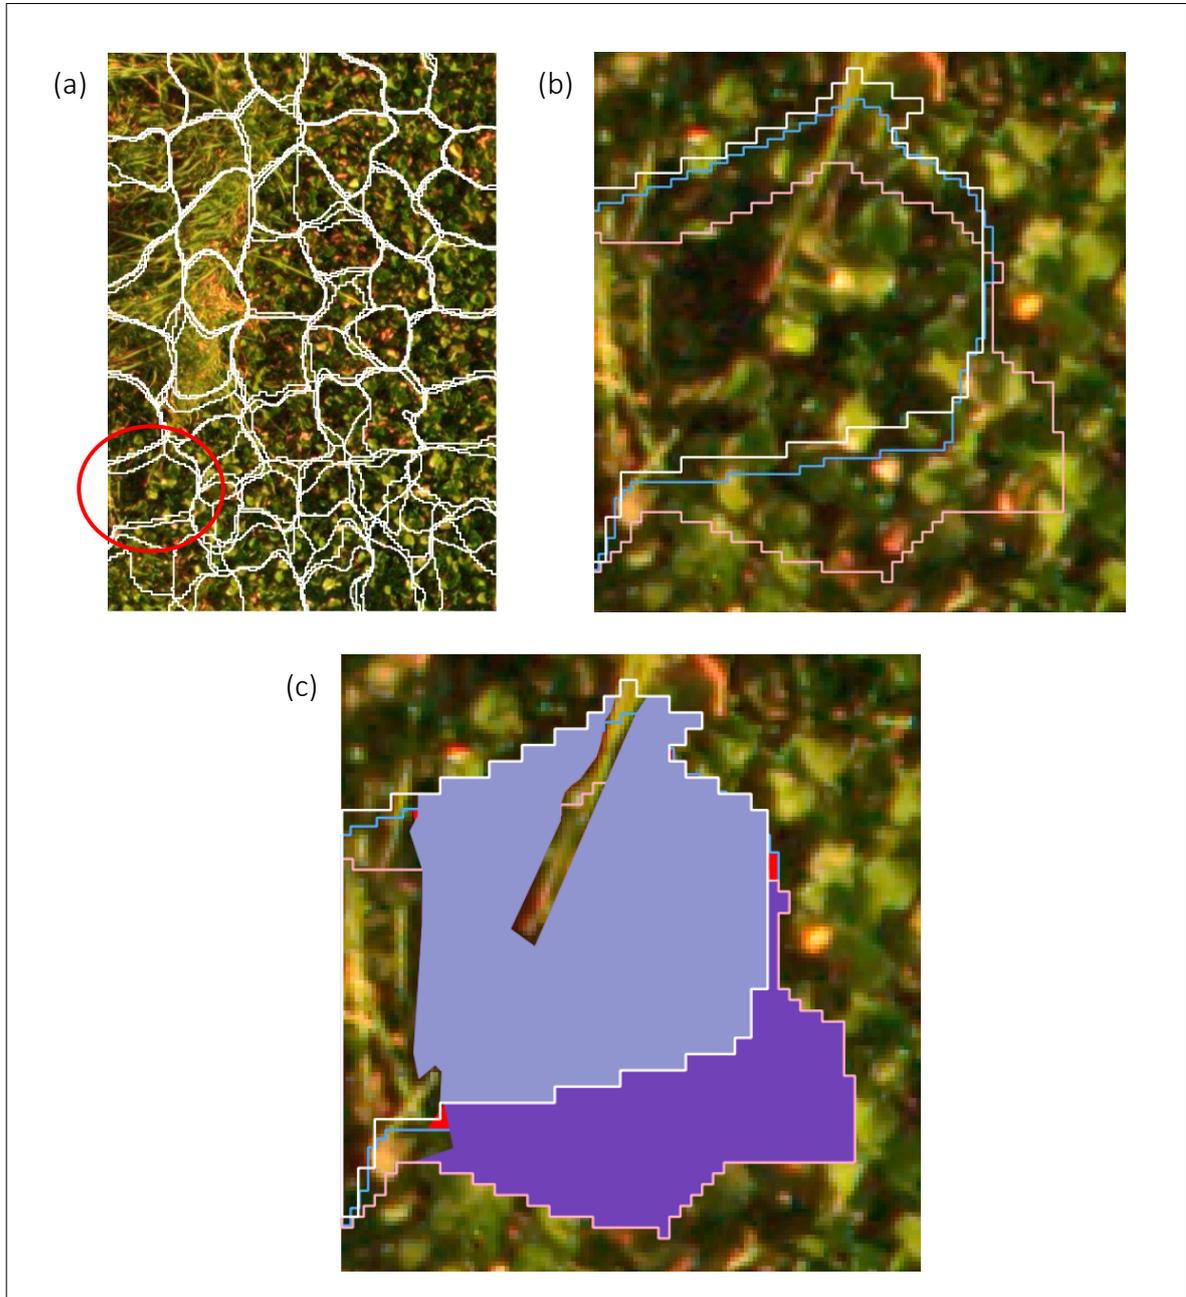
$$Precisão = \frac{\sum_{i=1}^n |S_i \cap R_i|}{\sum_{i=1}^n |S_i|} \quad (18)$$

A avaliação da acurácia das segmentações levou em consideração que cada recorte possui aproximadamente 48 segmentos. Dos 28 recortes, apenas 16 deles foram selecionados, pois possuem mais de uma espécie de VAE para ser separada. Os demais recortes dispõem de uma única espécie de VAE, portanto, os segmentos não têm mistura e foram desconsiderados nesta etapa.

Adotando-se um intervalo de confiança de 95%, foram amostrados aleatoriamente 12 segmentos de cada um dos 16 recortes, que corresponde a cerca de 30% de cada um, totalizando-se os mesmos 192 segmentos para cada uma das três segmentações. Dentre os segmentos amostrados, aqueles que continham mais de uma espécie foram selecionados e, em cada um, foi delimitado o polígono de referência, contendo os pixels referentes à classe temática majoritária, pois os segmentos que continham uma única espécie não precisaram de polígonos.

Em cada segmentação, o mesmo segmento pode apresentar-se de forma diferente, perdendo ou adquirindo pixels conforme a sua delimitação. Em vista disso, os polígonos de referência foram compatibilizados em relação às bordas em cada uma das três segmentações. Para ilustrar o que foi feito, a Figura 20 apresenta o recorte 6, que contém duas espécies de VAE na cena, e indica um dos segmentos com mistura entre espécies que foi selecionado (Figura 20b). A classe minoritária aparece na porção superior e lateral esquerda do segmento (Figura 20c), ausente no polígono criado.

Figura 20 - (a) Recorte 6 com destaque para (b) um segmento com as três segmentações, sendo o contorno rosa, azul e branco, respectivamente, as combinações (1) 1,6 cm + $\sigma = 6$, (2) 2 cm + $\sigma = 6$ e (3) 3 cm + $\sigma = 4$; (c) Compatibilização do polígono com cada borda do segmento em destaque. Todas as imagens estão com o fundo do recorte no nível original.



A avaliação da acurácia da segmentação teve como finalidade selecionar os níveis de subamostragem e suavização mais adequados para adotar uma única configuração desses parâmetros, que está relacionado ao interesse dos segmentos serem predominantemente constituídos de apenas uma espécie de VAE (sub-regiões homogêneas). Logo, foi selecionada a segmentação com o maior valor de Precisão (Segmentação 3), baseado nos segmentos amostrados. Neste caso, o erro não foi avaliado devido à falta de pixels da classe majoritária,

os quais estavam presentes nos segmentos vizinhos que não entraram na análise. Vale ressaltar que, nesta etapa e a partir dela, todos os processamentos e análises foram reproduzidos nos 28 recortes.

3.3.5 Extração de atributos espectrais e de textura

A extração de atributos foi feita diretamente dos recortes (arquivo Raster – dado matricial), delimitados pela segmentação (arquivo Shapefile – dado vetorial), portanto, os atributos são adotados para cada segmento (unidade de análise). Os atributos espectrais foram obtidos por meio da ferramenta Geographical Data Mining Analyst (GeoDMA) 2.0.3 beta, sistema de mineração de dados espaciais (KORTING et al., 2008), cujo funcionamento está interligado ao software TerraView 5.6.1. A Tabela 5 apresenta todos os atributos calculados pela ferramenta GeoDMA, que apesar de considerar todos como espectrais, há várias medidas estatísticas e de textura baseada na matriz GLCM, como, dissimilaridade, energia, entropia e homogeneidade. Além disso, apresenta outros atributos que também designam textura, como, contraste e coeficiente de variação.

Os índices de vegetação, NDVI e Razão Simples, também foram calculados, obtendo-se uma média de cada um por segmento, por meio do software QGIS 3.20.3-Odense, uma vez que poderiam contribuir para a distinção das espécies de VAE. Tanto os índices de vegetação quanto os atributos do GeoDMA foram extraídos dos recortes no nível original. No caso do SIFT, a extração dos pontos-chave com descritores foi feita a partir dos recortes nas suas versões subamostradas de 2 cm e 3 cm, utilizando a biblioteca Python *opencv* 4.5.3.56 (OpenCV, 2023).

As informações de textura SIFT foram utilizadas de duas maneiras. A primeira tendo em vista apenas a informação da localização dos pontos-chave nos recortes, sem os descritores, atributo denominado densidade de pontos. A segunda considerando as informações dos pontos-chave com seus 128 descritores para a descrição da textura. Todos os atributos mencionados, espectrais e de textura, foram extraídos de cada um dos segmentos dos 28 recortes.

Tabela 5 - Atributos gerados pela ferramenta GeoDMA.

Nome	Descrição	Equação
AMPL_BAND	Amplitude	$ampl = px_{max} - px_{min}$
BRATIO_BAND	Contribuição da banda para o segmento	$banda = \frac{\mu B_i}{\sum_{j=1}^{NB} \mu B_j}$
COUNT_BAND	Contagem de pixels	$N = contagem(X)$
CONTSE_BAND	Contraste	$contr = \sum_{i=0}^{D-1} \sum_{j=0}^{D-1} p_{i,j} \cdot i - j ^2$
DISSE_BAND	Dissimilaridade	$dissim = \sum_{i=0}^{D-1} \sum_{j=0}^{D-1} p_{i,j} \cdot i - j $
ENERGSE_BAND	Energia	$energ = \sum_{i=0}^{D-1} \sum_{j=0}^{D-1} p_{i,j}^2$
ENTRSE_BAND	Entropia	$entrop = - \sum_{i=1}^{D-1} \sum_{j=1}^{D-1} p_{ij} \cdot \log p_{ij}$
HOMOGSE_BAND	Homogeneidade	$homog = \sum_{i=1}^{D-1} \sum_{j=1}^{D-1} \frac{p_{ij}}{1 + (i - j)^2}$
KURT_BAND	Curtose	$K = \frac{n(n+1)(n-1)}{(n-2)(n-3)} \cdot \frac{\sum_{i=1}^N (px_i - \mu)^4}{(\sum_{i=1}^N (px_i - \mu)^2)^2}$
MAX_VAL_BAND	Valor máximo	$maxVal = \max(X)$
MEAN_BAND	Média	$\mu = \frac{\sum_{i=1}^N px_i}{N}$
MEDIAN_BAND	Mediana	$mediana = p \left(\frac{n+1}{2} \right)$
MIN_VAL_BAND	Valor mínimo	$minVal = \min(X)$
MODE_BAND	Moda	-
N_MOD_BAND	Número de modas do segmento	-
SKEW_BAND	Assimetria	$S = \frac{n\sqrt{n-1}}{n-2} \cdot \frac{\sum_{i=1}^N (px_i - \mu)^3}{(\sum_{i=1}^N (px_i - \mu)^2)^{\frac{3}{2}}}$
STDDEV_BAND	Desvio padrão	$\sigma = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (px_i - \mu)^2}$
SUM_BAND	Soma	$soma = \sum_{i=1}^N px_i$
VARCOEF_BAND	Coefficiente de variação	$c_v = \frac{100\sigma}{\mu}$
VAR_BAND	Variância	$s^2 = \frac{\sum_{i=1}^N (px_i - \mu)^2}{N-1}$

Fonte: Adaptado de DPI-INPE (2023)

Onde:

 px_i = valor do pixel;

px_{max} = valor máximo do pixel;

px_{min} = valor mínimo do pixel;

B = banda espectral;

NB = total de bandas espectrais;

X = objeto (segmento);

D = dimensão da matriz GLCM, a qual tem o mesmo intervalo de nível de cinza da imagem original;

p_{ij} = frequência relativa normalizada quando duas células vizinhas separadas por um deslocamento fixo ocorrem na imagem, uma com nível de cinza i e outra com nível cinza j ;

N ou n = quantidade de pixels dentro de um segmento (X);

σ = desvio padrão.

3.3.6 Seleção de atributos do GeoDMA e síntese dos descritores de textura SIFT

De acordo com a Tabela 5, deve-se levar em consideração que são 20 atributos espectrais por banda espectral, e como este estudo utiliza quatro bandas espectrais, logo, contabilizam-se 80 atributos calculados para cada segmento. A fim de elencar e selecionar os atributos de maior relevância, foi utilizado o método CFS com o algoritmo de busca BestFirst, do software WEKA 3.8.5, empregando a Validação Cruzada como o modo de seleção dos atributos.

Quanto aos descritores de textura SIFT, levando em consideração que cada segmento engloba vários pontos-chave, sendo que cada um é descrito por 128 atributos de textura com base em histogramas de gradientes (magnitude e orientação) locais, foi necessário sintetizá-los. Para obter apenas um ponto-chave por segmento, foram criadas três versões sintéticas, utilizando as medidas de coeficiente de variação (Equação 19), média (Equação 20) e mediana (ponto central de um conjunto de dados, que caso o número de pontos seja par, calcula-se a média dos dois pontos centrais) dos descritores dos pontos-chave, de modo a averiguar qual geraria o melhor resultado na etapa da classificação.

$$\bar{x} = \frac{\sum_{i=1}^n x_i}{n} \quad (19)$$

$$CV = \frac{S}{\bar{x}} \quad (20)$$

Onde:

\bar{x} = média;

x_i = observações;

n = nº de observações;

CV = coeficiente de variação;

$$S = \text{desvio padrão} \rightarrow S = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1}}$$

As três medidas mencionadas foram calculadas entre os pontos-chave de um mesmo segmento para cada um dos 128 atributos, por meio da biblioteca Python *pandas* 1.2.4 (Pandas, 2023), ou seja, a quantidade de pontos-chave é reduzida e os 128 atributos são mantidos. Esse procedimento foi realizado para todos os segmentos de todos os recortes, tanto para a subamostragem de 2 cm quanto de 3 cm. O intuito de criar o ponto-chave sintético foi reduzir a quantidade de dados gerados pelo SIFT e encontrar atributos de textura que possam unicamente representar uma determinada espécie de VAE.

3.3.7 Classificação

Todas as classificações foram realizadas com Random Forest, no software WEKA 3.8.5. A primeira etapa consiste no treinamento do modelo de predição, portanto, as classes temáticas foram definidas a priori, de acordo com as espécies de VAE identificadas na área imageada do reservatório: aguapé, erva-de-jacaré e taboa. Destaca-se que os mapas de classificação apresentam a classe água, no entanto, ela não foi incluída no treinamento, pois uma máscara foi utilizada para rotulá-la manualmente.

As amostras de treinamento e validação (segmentos) foram selecionadas no QGIS 3.20.3-Odense a partir dos segmentos dos 28 recortes. Para o treinamento, 1095 segmentos foram selecionados (80%), e para a validação, 220 segmentos (20%), levando em consideração a proporção entre as classes. A Tabela 6 discrimina os segmentos por classe temática entre treinamento e validação.

Tabela 6 - Discriminação do número de segmentos para treinamento e validação, por classe temática.

Classe temática	Nº de segmentos de treinamento	Nº de segmentos de validação
Aguapé	476	94
Erva-de-jacaré	361	73
Taboa	257	53

Os segmentos foram selecionados por meio do seu número identificador (atributo ID), e exportados em formato de planilha do Excel (XLSX), uma para o treinamento e outra para a validação. As tabelas foram organizadas no Excel de forma a compor todos os atributos, e convertidas para o formato *Comma separated values* (CSV), reconhecido pelo software WEKA. Os atributos de interesse foram selecionados para cada conjunto de dados (Tabela 7), gerando-se dois arquivos, um de treinamento e outro de validação, ambos no formato Attribute-Relation File Format (ARFF), padrão WEKA.

Uma vez selecionados os atributos, foi possível compor diferentes conjuntos de dados para serem classificados: utilizando somente atributos de textura, do SIFT ou GeoDMA, contendo apenas atributos espectrais do GeoDMA, adicionando os índices de vegetação e densidade de pontos. No caso do SIFT, como mencionado, foram criados seis tipos de pontos-chave sintéticos (2cm_coef_var, 2cm_média, 2cm_mediana, 3cm_coef_var, 3cm_média e 3cm_mediana), para determinar o mais consistente. Os descritores de textura SIFT de cada um deles foram classificados preliminarmente com Random Forest. Dentre os seis, o ponto-chave sintético 2cm_média gerou o maior valor de acurácia, sendo assim, esses dados foram integrados nos conjuntos criados para a classificação. A Tabela 7 especifica a composição de todos eles.

Os conjuntos de dados 1 e 2 são comparáveis, contêm informação de textura procedente do SIFT e GeoDMA, respectivamente. O conjunto de dados 3 compreende apenas atributos espectrais, aos quais vão sendo acrescentadas camadas (atributos) para verificar a contribuição de cada atributo por meio da acurácia global, como foi feito nos estudos de Geng et al. (2021) e Zhou et al. (2021) para o mapeamento de vegetação aquática. Desse modo, o conjunto de dados 4 insere os atributos de textura do GeoDMA (coeficiente de variação, contraste, dissimilaridade e entropia) não contemplados no 3; em 5, adiciona-se os índices de vegetação; e 6 inclui a densidade de pontos. O conjunto de dados 7 retira os atributos mencionados e os de textura do GeoDMA, substituindo pelos descritores de textura SIFT e mantendo apenas os atributos espectrais, por fim, em 8 os atributos retirados são reintroduzidos para classificar com todos os atributos e verificar o resultado.

Tabela 7 - Descrição da composição dos conjuntos de dados criados para a classificação.

Conjunto de dados	Nº de atributos	Composição do conjunto de dados	Descrição
1	128	Descritores de textura SIFT	Atributos de textura do SIFT
2	16	Coefficiente de variação, contraste, dissimilaridade e entropia das quatro bandas espectrais	Atributos de textura do GeoDMA
3	24	Amplitude, curtose, valor máximo, média, mediana e assimetria das quatro bandas espectrais	Atributos espectrais
4	40	Amplitude, curtose, valor máximo, média, mediana, assimetria, coeficiente de variação, contraste, dissimilaridade e entropia das quatro bandas espectrais	Atributos espectrais e de textura do GeoDMA
5	42	Amplitude, curtose, valor máximo, média, mediana, assimetria, coeficiente de variação, contraste, dissimilaridade e entropia das quatro bandas espectrais + índices de vegetação	Atributos espectrais e de textura do GeoDMA, adicionando índices de vegetação
6	43	Amplitude, curtose, valor máximo, média, mediana, assimetria, coeficiente de variação, contraste, dissimilaridade e entropia das quatro bandas espectrais + índices de vegetação + densidade de pontos	Atributos espectrais e de textura do GeoDMA, adicionando índices de vegetação e densidade de pontos
7	152	Amplitude, curtose, valor máximo, média, mediana e assimetria das quatro bandas espectrais + descritores de textura SIFT	Atributos espectrais do GeoDMA e descritores de textura SIFT
8	171	Amplitude, curtose, valor máximo, média, mediana, assimetria, coeficiente de variação, contraste, dissimilaridade e entropia das quatro bandas espectrais + índices de vegetação + densidade de pontos + descritores de textura SIFT	Atributos espectrais e de textura do GeoDMA, adicionando índices de vegetação, densidade de pontos e descritores de textura SIFT

Cada um dos conjuntos de dados foi treinado individualmente com Validação Cruzada, utilizando 10 folds, alterando o número de árvores de 100 (valor padrão) até 500, incrementado em 100. Os demais parâmetros permaneceram no valor padrão. Após treinados todos os modelos, cada um foi validado com o arquivo de validação correspondente. Os dados de treinamento e validação foram os mesmos para todos os conjuntos de dados, selecionados por meio de interpretação visual, uma vez que não foi possível obter autorização para acessar os locais de barco e coletar os dados de campo, além disso, as imagens de alta resolução espacial obtidas por VARP facilitam essa tarefa, são menos dependentes das observações de campo do que é requerido para as imagens de menor resolução espacial (CHABOT et al., 2018).

Quanto à área teste, foram classificados 2102 segmentos utilizando os mesmos dados de treinamento dos recortes, e 902 segmentos de água foram retirados com auxílio do SIFT (máscara), que não gerou pontos-chave para os segmentos da superfície d'água, uma vez que a textura é homogênea e não produz gradientes. Sendo assim, os mapas de classificação foram elaborados para a área teste levando em consideração os 8 conjuntos de dados, no QGIS 3.20.3-Odense, importando os dados classificados do WEKA.

Para avaliar a acurácia das classificações, foi calculada a matriz de confusão (STORY; CONGALTON, 1986; CONGALTON, 2001) a fim de verificar os erros e acertos da classificação de forma geral e de cada classe, a partir da acurácia global e coeficiente Kappa, e das acurácias do produtor e usuário. A validação foi expressa apenas em matrizes de confusão, pois se tratava dos recortes esparsos, difíceis de serem apresentados como mapas de classificação, enquanto o resultado das classificações da área teste foi apresentado por meio dos mapas de classificação e das acurácias e coeficiente Kappa em forma de tabelas, com a finalidade de apresentar os resultados obtidos pelo método implementado.

4 RESULTADOS E DISCUSSÃO

Esta seção apresenta os resultados obtidos, que compreendem os experimentos de segmentação, e a classificação dos segmentos dos recortes e da área teste, que foi utilizado para apresentar os mapas de classificação.

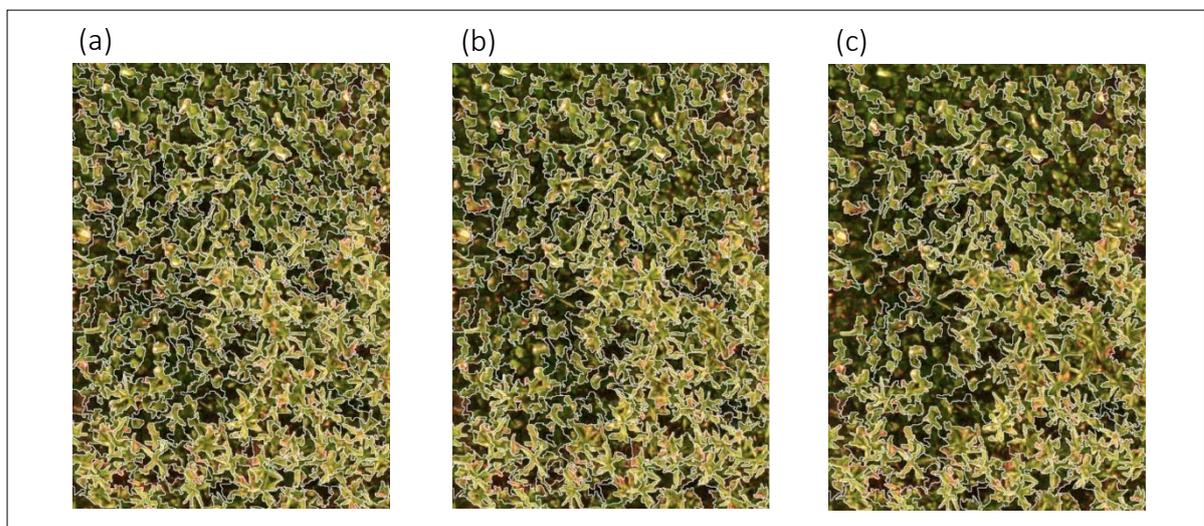
4.1 Segmentação

Os experimentos estão divididos por algoritmo, sendo que cada um deles foi explorado para os três recortes subamostrados e suavizados, a fim de comparar e selecionar um dos algoritmos de segmentação e definir os parâmetros mais adequados.

4.1.1 Experimento 1: Crescimento de Regiões

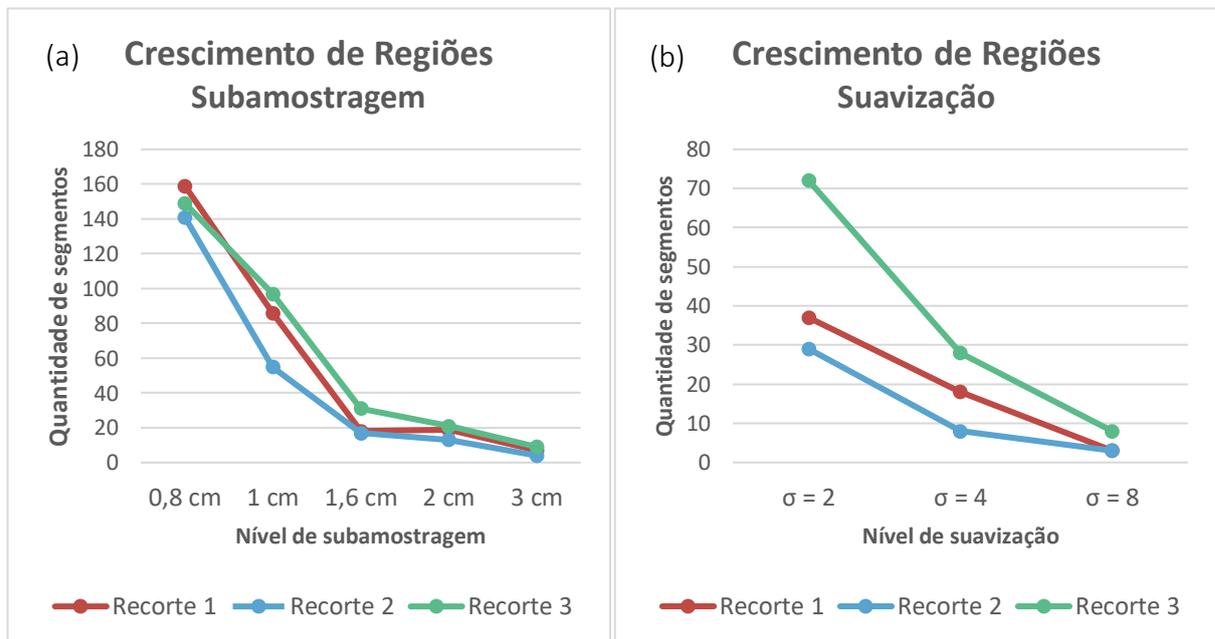
O algoritmo Crescimento de Regiões exige a definição de dois parâmetros: limiar de similaridade e limiar de área. Empiricamente, constatou-se que estabelecer valores abaixo de 50 para a similaridade causava uma segmentação excessiva (super-segmentação), como exemplificada na Figura 21, produzindo regiões que representam detalhes dentro da cobertura com a mesma espécie. Por outro lado, estabelecer valores acima de 80, começava a gerar segmentos insuficientes (sub-segmentação). A Figura 21 mostra o efeito da super-segmentação, utilizando três limiares de similaridade abaixo de 50 para o recorte 1, no nível original.

Figura 21 - Efeito da super-segmentação utilizando três limiares de similaridade abaixo de 50 para o recorte 1, no nível original: (a) Similaridade: 20/Área: 200; (b) Similaridade: 30/Área: 200; (c) Similaridade: 40/Área: 200. Todas as segmentações estão com o fundo do recorte no nível original.



Quanto ao limiar de área, foi delimitado o intervalo de 50 a 200, pois a definição de valores fora desse limite também causava os efeitos de super-segmentação e sub-segmentação, sem a melhoria da qualidade da segmentação. No entanto, as delimitações dos limiares não garantem a isenção dos efeitos mencionados, apenas a possível diminuição deles. Dentre os pares de limiares testados, a segmentação com os parâmetros 70/200 (similaridade/área) gerou a menor quantidade de segmentos para os três recortes, sendo selecionada para comparar a segmentação das subamostragens e das suavizações (Figuras 22a-b).

Figura 22 - Comparação da (a) subamostragem e (b) suavização quanto à quantidade de segmentos gerados a partir do algoritmo Crescimento de Regiões, utilizando os seguintes parâmetros: Similaridade: 70/Área: 200.



A partir dos testes, foi possível observar que a definição de limiares menores criou muitos segmentos, tanto para o limiar de similaridade quanto para o limiar de área, pois a exigência para formar uma região é maior. Portanto, formaram-se mais segmentos nas imagens de 0,8 cm e subamostrada de 1 cm devido à maior variabilidade da resposta espectral no espaço. As Figuras 22a-b mostram a tendência da diminuição de segmentos à medida que o nível de detalhamento diminui, o que indica, como esperado, que a subamostragem e a suavização detectam menos detalhes da imagem. Quando comparadas, a suavização gera aproximadamente 70% menos segmentos no primeiro nível de suavização que o primeiro nível de subamostragem, e nos demais níveis tendem a se equipararem.

Uma vez que a diminuição da resolução espacial gera menos segmentos, nota-se que o algoritmo Crescimento de Regiões é mais sensível ao nível de detalhamento das imagens de 0,8

cm e 1 cm em relação às demais. Além disso, constata-se nas Figuras 21a-b que a definição dos mesmos limiares para os três recortes gerou uma quantidade diferente de segmentos. Tal comportamento pode estar atrelado às particularidades de cada região (recorte), visto que cada uma delas apresenta espécies diferentes de VAE, organizadas espacialmente de forma distinta.

Para o recorte 1, a subamostragem de 3 cm segmentada conseguiu separar as duas espécies de VAE de forma satisfatória (Figura 23d), enquanto as de 0,8 cm e 1 cm ficaram super-segmentadas. O mesmo ocorreu para os recortes 2 e 3, no entanto, no recorte 2, apenas a segmentação da subamostragem de 2 cm (Figura 23e) foi consistente; e no caso do recorte 3, nenhuma subamostragem segmentada conseguiu delimitar as espécies satisfatoriamente, apenas a subamostragem de 3 cm (Figura 23f) aproximou-se disso.

Nota-se que o delineamento apresentou falhas em todos os recortes, uma vez que englobou indivíduos que não fazem parte da cobertura da mesma espécie, bem como deixou alguns deles de fora devido ao emaranhado entre espécies. De forma geral, o recorte 3 aparentemente obteve resultados menos eficientes na separação de VAE, o que pode estar relacionado à própria organização espacial delas.

A partir das Figuras 23 e 24, também é possível observar que o algoritmo Crescimento de Regiões visualmente parece destacar regiões de sombra, mais facilmente notável nas Figuras 23f e 24c, que pode ser devido ao maior espaçamento entre as espécies de VAE. A Figura 24 mostra que, para os parâmetros 70/200 (similaridade/área) considerados, a suavização não gerou agrupamentos visualmente correspondentes à separação das espécies de VAE, indicando que a subamostragem se sobressaiu nesse caso. Portanto, a partir do experimento realizado foi possível constatar que o algoritmo Crescimento de Regiões demonstrou ser sensível às mudanças de iluminação e, principalmente, afetado pela resolução espacial.

Figura 23 - As segmentações que conseguiram delinear melhor as espécies de cada recorte a partir do algoritmo Crescimento de Regiões, utilizando os seguintes parâmetros: Similaridade: 70/Área: 200. Recortes (a) 1, (b) 2 e (c) 3 para fins de comparação com a segmentação das subamostragens de (d) 3 cm, (e) 2 cm e (f) 3 cm, respectivamente. Todas as segmentações estão com o fundo do recorte no nível original.

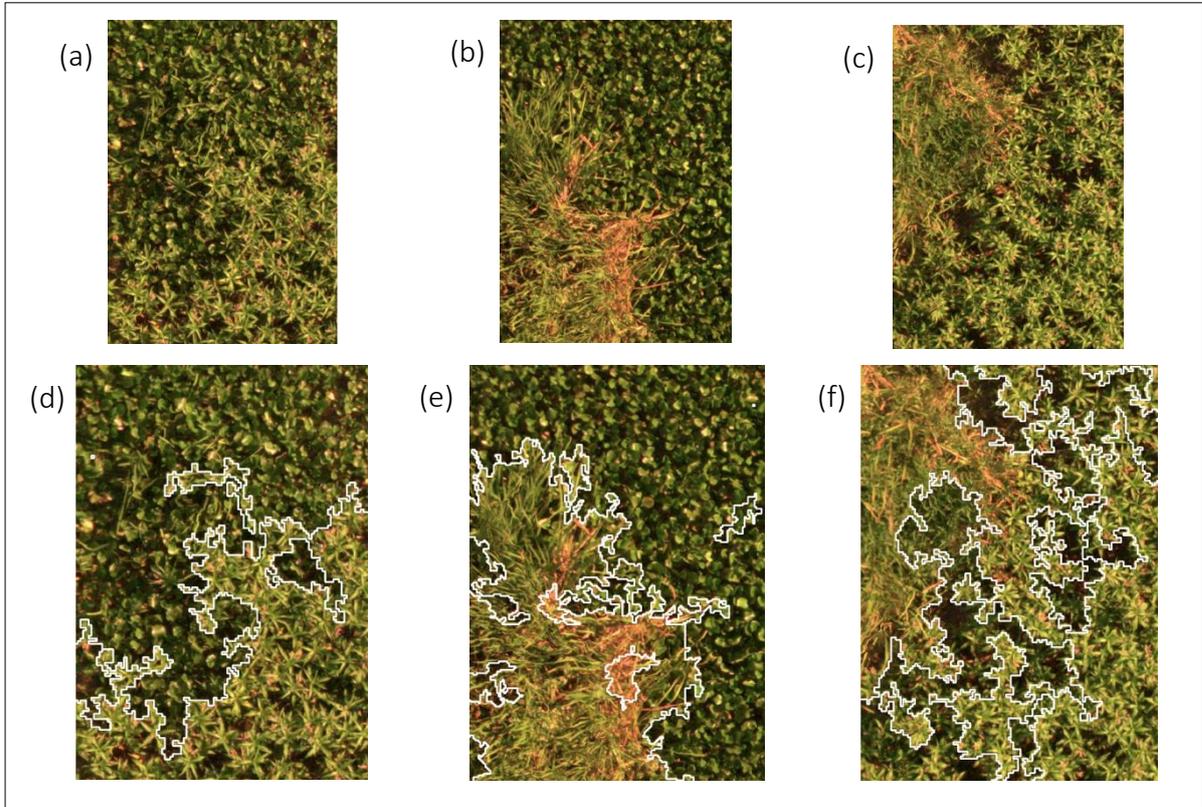
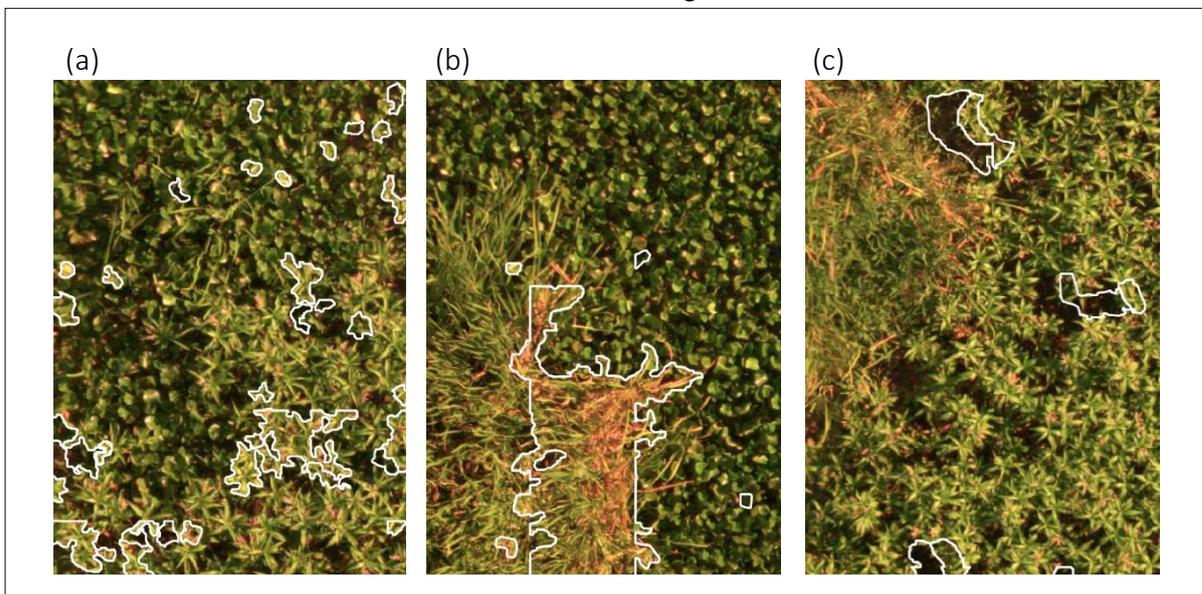


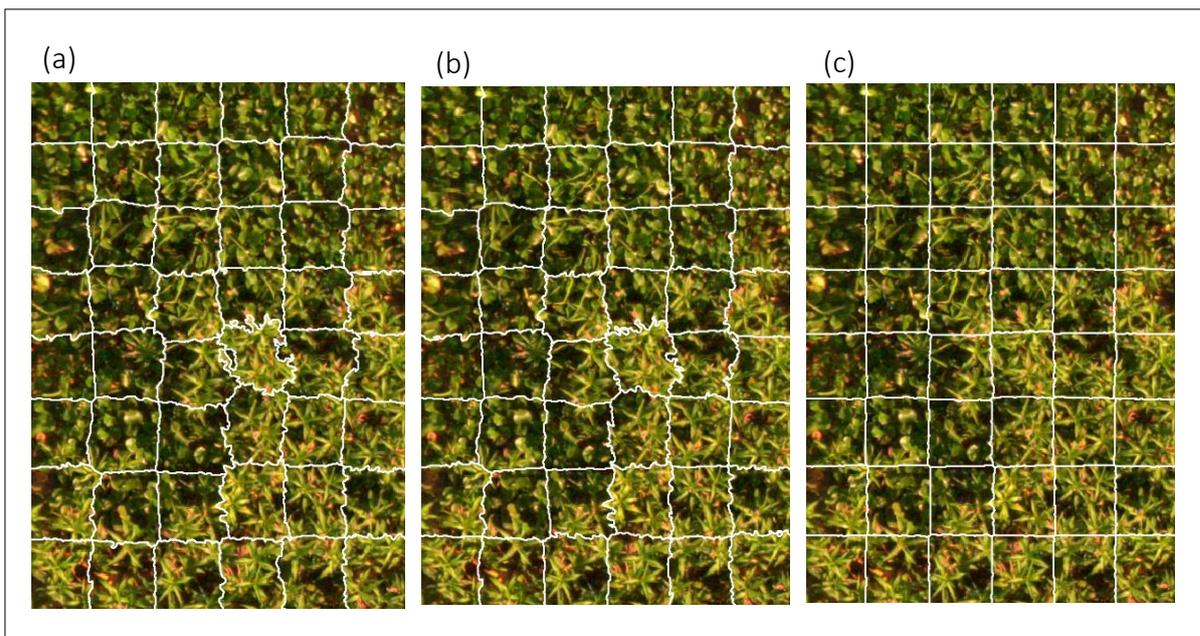
Figura 24 - Comparação da segmentação dos recortes (a) 1, (b) 2 e (c) 3 entre as diferentes suavizações a partir do algoritmo Crescimento de Regiões, com os seguintes parâmetros: Similaridade: 70/Área: 200. (a) $\sigma=2$; (b) $\sigma=4$; (c) $\sigma=8$. Todas as segmentações com o fundo do recorte no nível original.



4.1.2 Experimento 2: Superpixel

O algoritmo Superpixel requisita a definição do parâmetro k , quantidade de segmentos; sendo possível também alterar m , compacidade, que corresponde ao formato. Para a compacidade, quanto maior o valor de m , mais regulares e rígidos serão os segmentos; e quanto menor, mais irregulares e flexíveis. Experimentalmente, verificou-se que, para as imagens utilizadas, valores entre 1 e 100 não modificavam o formato dos segmentos gerados. Foram notadas mudanças somente a partir de 100, resultando em segmentos mais regulares e rígidos, como mostra a Figura 25. Portanto, manteve-se a compacidade com valor 10, o valor padrão do algoritmo.

Figura 25 - Comparação da segmentação com Superpixel do recorte 1 no nível original, alterando os valores de compacidade: (a) 10 (padrão do algoritmo); (b) 250; (c) 500. Todas as segmentações estão com o fundo do recorte no nível original.

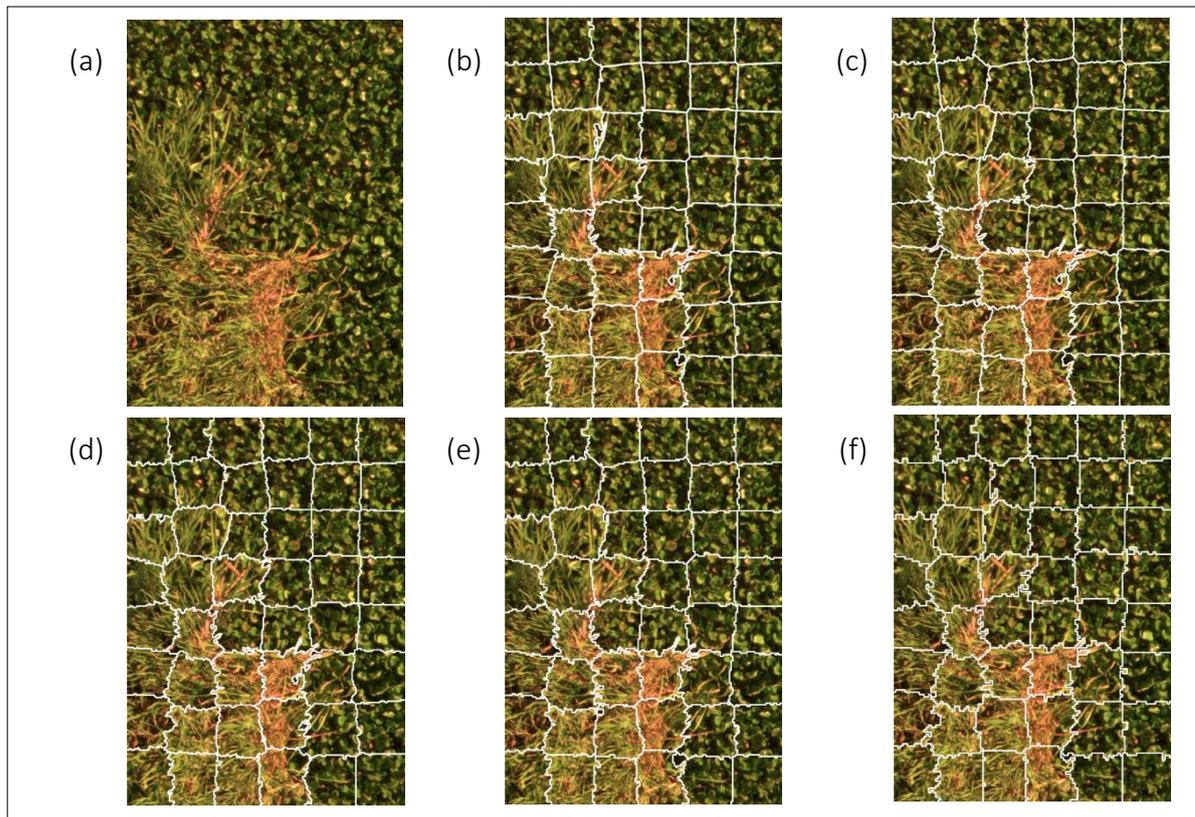


Quanto ao parâmetro k , é importante lembrar que corresponde a um valor aproximado de segmentos que serão gerados. Assim, constatou-se que aproximadamente 50 segmentos seriam suficientes para abranger uma espécie de VAE em cada segmento, pois valores acima criariam segmentos muito pequenos ao considerar a concepção de conjunto de plantas. Logo, os parâmetros 10/50 (compacidade/quantidade de segmentos) foram utilizados para comparar a segmentação das subamostragens e das suavizações.

O algoritmo Superpixel mantém constância na quantidade de segmentos gerados nos três recortes para todos os níveis de subamostragem e suavização. Isso significa que a mesma

quantidade, 48 segmentos, é mantida entre os três recortes, não importando o nível de detalhamento das imagens. Visualmente, constata-se que a segmentação das subamostragens não apresentou diferenças significativas com a variação do tamanho do pixel, exemplificada no recorte 2 (Figuras 26a-f) como foi para o algoritmo Crescimento de Regiões. Notam-se mudanças sutis nas bordas, conforme o tamanho do pixel aumenta, visto que esses contornos ficam mais irregulares e evidenciam-se na segmentação das subamostragens de 2 cm e 3 cm dos três recortes. De forma geral, os segmentos mantiveram sua forma nos níveis de subamostragem.

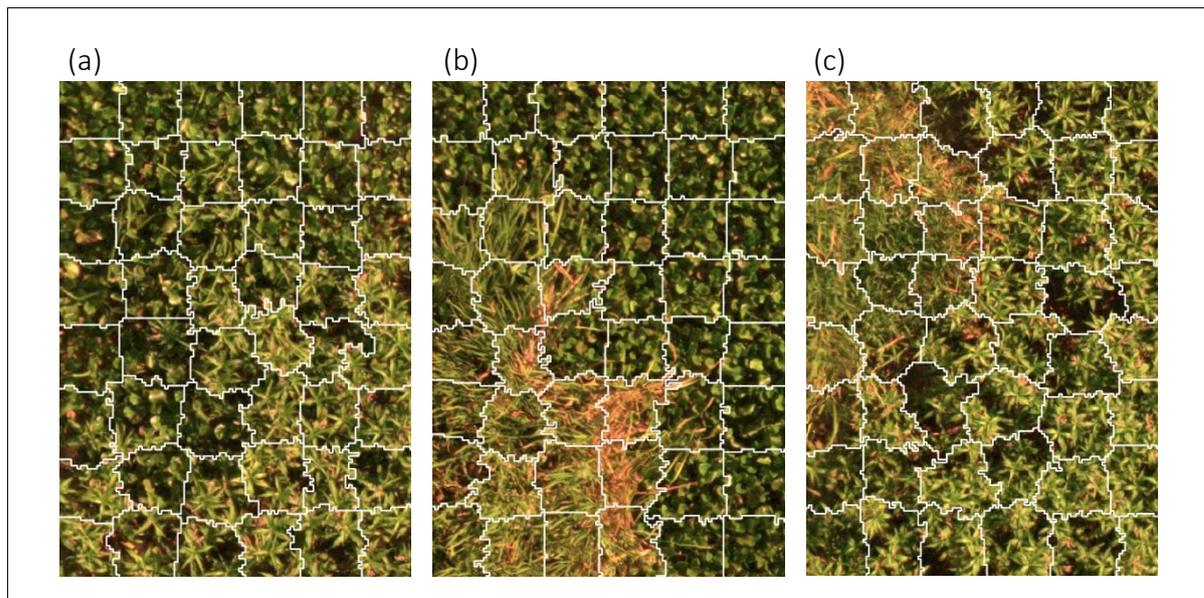
Figura 26 - Comparação da segmentação do recorte 2 entre as diferentes subamostragens a partir do algoritmo Superpixel, com os seguintes parâmetros: Compacidade: 10/Quantidade de segmentos: 50. (a) Recorte 2 para fins de visualização; (b) Nível original (0,8 cm); (c) 1 cm; (d) 1,6 cm; (e) 2 cm; (f) 3 cm. Todas as segmentações estão com o fundo do recorte no nível original.



Para fins de comparação entre os recortes, as Figuras 27a-c utilizaram a segmentação da subamostragem de 3 cm. O recorte 1 (Figura 27a) criou segmentos contendo um conjunto de uma mesma espécie de VAE na parte superior esquerda e de outra espécie na região inferior direita da imagem, já na porção central é possível notar que há mistura. Em relação ao recorte 1, os recortes 2 (Figura 27b) e 3 (Figura 27c) separaram bem as duas espécies, com menos mistura na região de transição entre elas. No entanto, no recorte 3, a organização espacial de

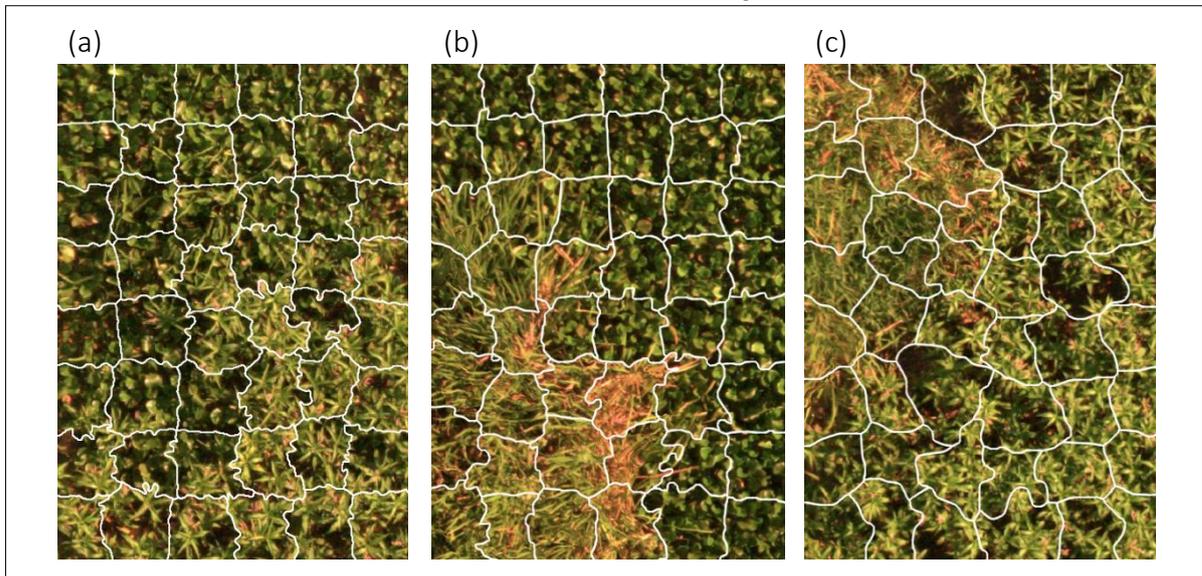
VAE contém mais espaçamento entre si do que os demais recortes, criando alguns segmentos que englobam menos plantas e mais sombras. Para a subamostragem, aparentemente foi mais difícil separar as espécies do recorte 1, pois são visualmente mais similares, quando comparadas às espécies presentes nos recortes 2 e 3.

Figura 27 - Comparação das subamostragens de 3 cm dos recortes (a) 1, (b) 2 e (c) 3 segmentadas a partir do algoritmo Superpixel, com os seguintes parâmetros: Compacidade: 10/Quantidade de segmentos: 50. Todas as segmentações estão com o fundo do recorte no nível original.



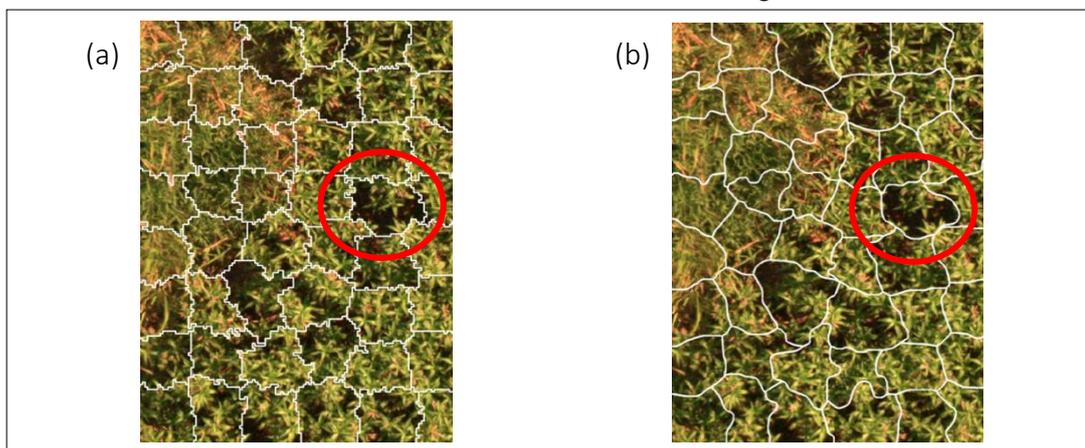
A partir das Figuras 28a-c, é possível verificar o mesmo comportamento na suavização, isto é, os segmentos gerados conseguiram contornar e separar melhor as espécies de VAE nos recortes 2 e 3, como no caso da subamostragem. A suavização se diferencia pelos segmentos com bordas mais suaves e formatos mais flexíveis, característica que se acentua ao aumentar o grau de suavização, reduzindo a rigidez dos segmentos gerados na subamostragem.

Figura 28 - Comparação da segmentação dos recortes (a) 1, (b) 2 e (c) 3 entre as diferentes suavizações a partir do algoritmo Superpixel, com os seguintes parâmetros: Compacidade: 10/Quantidade de segmentos: 50. (a) $\sigma=2$; (b) $\sigma=4$; (c) $\sigma=8$. Todas as segmentações estão com o fundo do recorte no nível original.



No caso do Superpixel, a suavização se destacou, pois visualmente os segmentos são melhores definidos quanto à borda. Na subamostragem (Figuras 27a-c), observa-se um contorno muito detalhado do entorno, detalhes esses que não contribuem significativamente na qualidade da separação entre as espécies. Para demonstrar esse comportamento, a Figura 29 destaca o mesmo segmento do recorte 3 na subamostragem e na suavização, sendo possível notar que os detalhes da borda na Figura 29a não acrescentam informações relevantes em comparação à Figura 29b. Portanto, a suavização teve resultados mais consistentes para o algoritmo Superpixel.

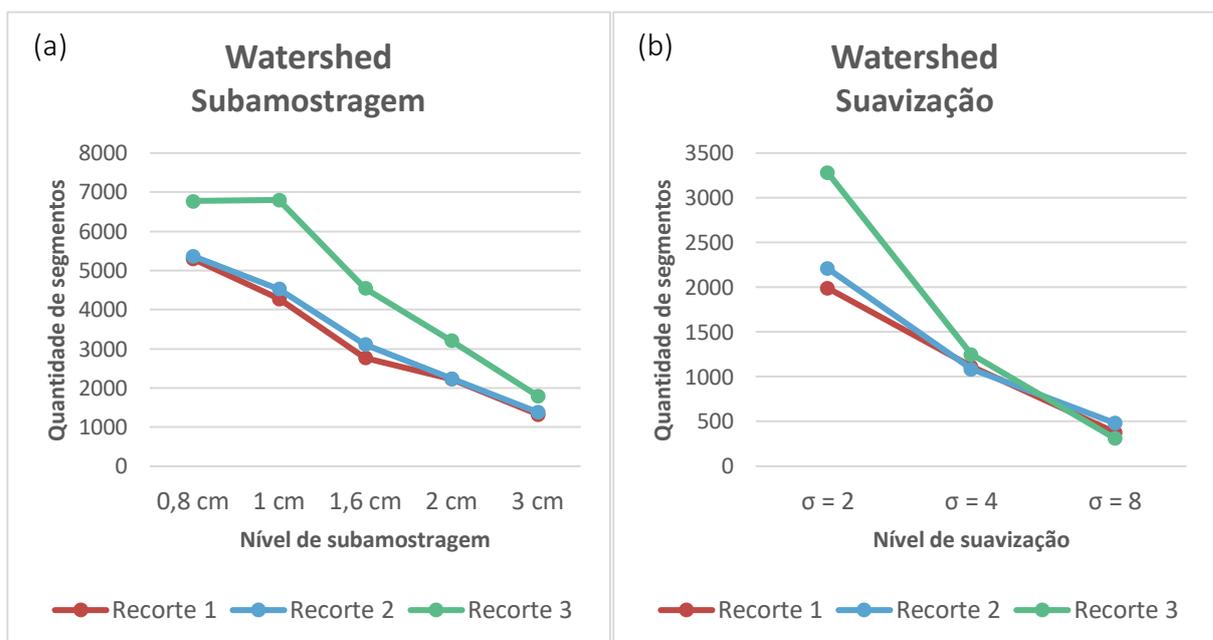
Figura 29 - Comparação de um mesmo segmento na (a) subamostragem (3 cm) e na (b) suavização ($\sigma=8$) do recorte 3 para o algoritmo Superpixel, com os seguintes parâmetros: Compacidade: 10/Quantidade de segmentos: 50. Todas as segmentações estão com o fundo do recorte no nível original.



4.1.3 Experimento 3: Watershed

Dentre os parâmetros que podem ser definidos para o algoritmo Watershed, depth threshold e flood level são primordiais para o funcionamento adequado do algoritmo, o qual por si só já tem como uma de suas limitações o efeito da super-segmentação. Após vários testes, os resultados obtidos ainda foram majoritariamente super-segmentados, mas para fins de comparação, a segmentação com os parâmetros 0,01/0,3 (depth threshold/flood level) gerou a menor quantidade de segmentos para os três recortes, sendo utilizada para comparar a segmentação das subamostragens e das suavizações (Figuras 30a-b).

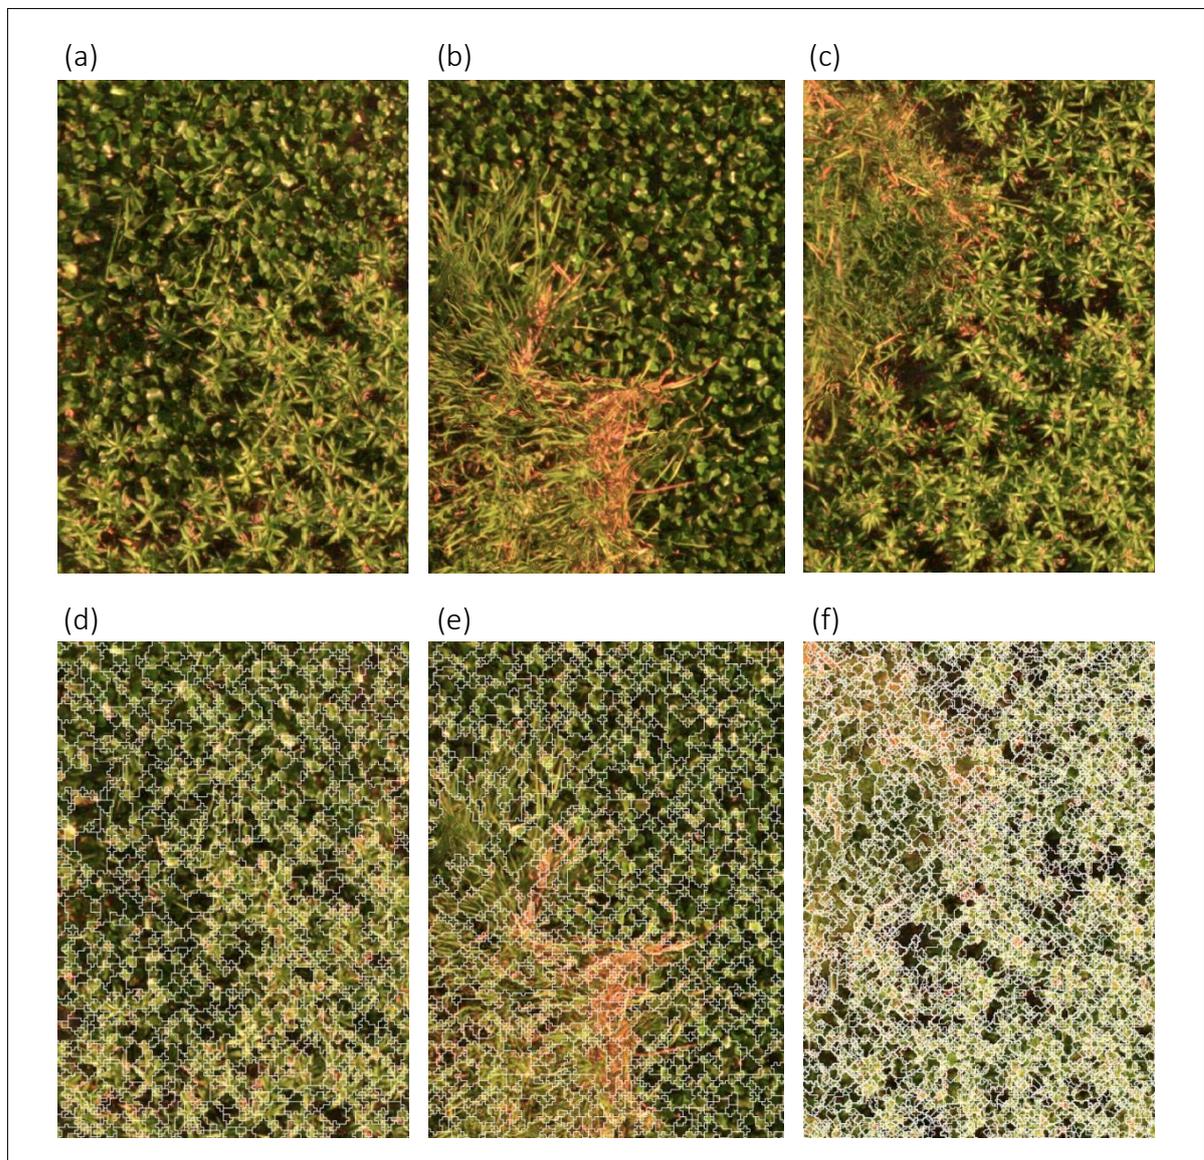
Figura 30 - Comparação da (a) subamostragem e (b) suavização quanto à quantidade de segmentos gerados a partir do algoritmo Watershed, utilizando os seguintes parâmetros: Depth threshold: 0,01/Flood level: 0,3.



A partir das Figuras 30a-b, é possível constatar o comportamento similar ao algoritmo Crescimento de Regiões (Figuras 22a-b), pois ao diminuir o nível de detalhamento, também reduz a quantidade de segmentos formados. No caso do algoritmo Watershed, o decréscimo foi em torno de 75% do primeiro ao último nível de subamostragem, e cerca de 85% do primeiro ao último nível de suavização. A principal diferença entre os algoritmos é a quantidade de segmentos gerados, visto que Crescimento de Regiões gerou 97% e 98% menos segmentos no primeiro nível de subamostragem e suavização, respectivamente, em relação aos mesmos níveis do algoritmo Watershed.

A Figura 31 apresenta a segmentação com os parâmetros 0,01/0,3 (depth threshold/flood level) da subamostragem de 3 cm para os três recortes, mostrando que o algoritmo Watershed não foi consistente para a segmentação das subamostragens, pois detectou detalhes em excesso, causando o efeito da super-segmentação. No entanto, a subamostragem contribuiu significativamente para a diminuição da quantidade de segmentos, assim como a suavização.

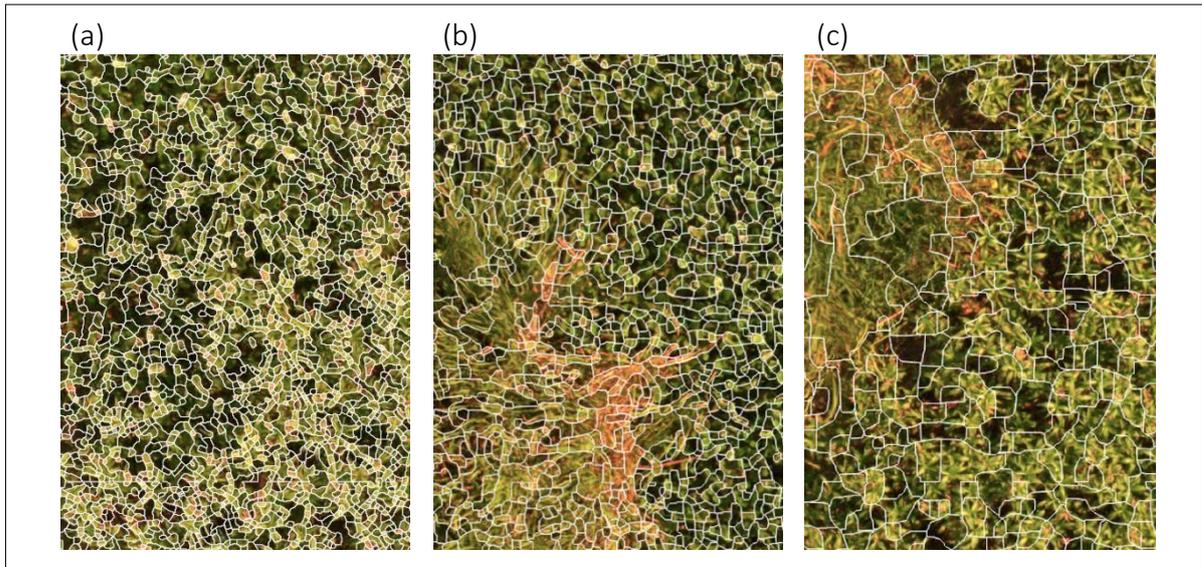
Figura 31 - Comparação da segmentação dos recortes (d) 1, (e) 2 e (f) 3 entre as subamostragens de 3 cm a partir do algoritmo Watershed, com os seguintes parâmetros: Depth threshold: 0,01/Flood level: 0,3. Recortes 1, (b) 2 e (c) 3 para fins de visualização. Todas as segmentações estão com o fundo do recorte no nível original.



No caso da suavização, os dois primeiros níveis mantiveram o efeito da super-segmentação (Figuras 32a-b), mas o terceiro e maior nível ($\sigma = 8$) gerou resultados consistentes, aparentemente delineando de forma satisfatória as espécies de VAE e formando segmentos

maiores, como exemplificado pela Figura 32c, no recorte 3. Portanto, a suavização se sobressaiu em relação à subamostragem para o algoritmo Watershed, o qual mostrou ser mais afetado pelo alto nível de detalhamento do que o algoritmo Crescimento de Regiões.

Figura 32 - Comparação da segmentação dos recortes (a) 1, (b) 2 e (c) 3 entre as diferentes suavizações a partir do algoritmo Watershed, com os seguintes parâmetros: Depth threshold: 0,01/Flood level: 0,3. (a) $\sigma=2$; (b) $\sigma=4$; (c) $\sigma=8$. Todas as segmentações estão com o fundo do recorte no nível original.



4.1.4 Seleção do algoritmo e avaliação da acurácia da segmentação

Os experimentos foram realizados com o intuito de investigar e selecionar um algoritmo de segmentação que particionasse as regiões com VAE em sub-regiões homogêneas. Dentre os algoritmos explorados, Superpixel foi selecionado levando em consideração a busca por regiões representativas das variações espectrais e de textura da cobertura da mesma espécie de VAE, evitando a criação de segmentos individuais de apenas detalhes, como, folhas, sombras e espaçamento entre as plantas.

Além disso, a definição dos parâmetros do Superpixel é trivial, enquanto Crescimento de Regiões e Watershed requerem muitos testes até encontrar os mais adequados, e mesmo assim, o que se adequa a uma região, muitas vezes não se adequa à outra, pois esses parâmetros ótimos podem não ser os mesmos para cada região, dependendo do conteúdo de espécies presentes na cena. Assim, o algoritmo Superpixel foi adotado por ser uma metodologia padrão para os três recortes trabalhados e testados, que pôde ser facilmente expandido para os demais recortes.

A combinação da subamostragem com a suavização gerou os resultados mais consistentes, quando comparada as duas abordagens isoladas, resultando em três segmentações finais (Tabela 8). Dentre os 192 segmentos amostrados, na segmentação 1 (1,6 cm + $\sigma = 6$), foi constatado 35 segmentos com mistura de espécies de VAE, enquanto nas segmentações 2 (2 cm + $\sigma = 6$) e 3 (3 cm + $\sigma = 4$), foram identificados 34 segmentos, um a menos. Sendo assim, as segmentações 2 e 3 se sobressaíram, e entre as duas, a segmentação 3 resultou em um valor maior de precisão, ainda que apenas com 1,2% de diferença. Logo, foi selecionada a segmentação do Superpixel para a subamostragem de 3 cm e suavização de $\sigma = 4$.

Tabela 8 - Comparação entre as segmentações com as três combinações de subamostragem e suavização do algoritmo Superpixel, com o maior valor de Precisão destacado em negrito. CL = coluna/linha; ID = identificador do segmento.

CL	(1) 1,6 cm + $\sigma = 6$			(2) 2 cm + $\sigma = 6$			(3) 3 cm + $\sigma = 4$		
	ID	Segmento	Polígono ref.	ID	Segmento	Polígono ref.	ID	Segmento	Polígono ref.
C2L5	23	4998	2698	26	4673	2569	25	5463	3281
C5L4	20	5210	3121	20	5242	3575	23	4274	2849
C6L3	14	5251	4930	13	4847	4616	15	4677	4312
C5L7	39	5515	2543	-	-	-	-	-	-
C2L1	1	4101	2373	1	4373	2664	1	4335	2745
C1L7	37	7431	5689	38	8635	6987	37	7286	5486
C2L6	33	3634	2800	34	5509	2981	30	3681	2882
C3L3	12	6022	3181	12	6183	3551	12	4176	3521
C1L5	33	7221	5874	33	7139	5610	33	7157	5569
C3L8	45	5129	3464	45	5157	3275	45	5235	3430
C4L3	15	5873	3057	14	5977	3023	14	6232	3251
C5L3	17	5947	4837	17	5542	4439	17	6144	5155
C6L1	5	5697	4104	5	6170	4132	5	6303	4230
C1L8	45	4929	3110	44	4664	2869	47	4649	2735
C5L8	43	7789	5575	43	7742	5596	44	7893	5710
C1L6	30	3825	1990	31	3389	1672	31	3672	1944
C2L7	36	3675	3230	35	4429	3841	35	3805	3323
C3L6	35	4647	2022	35	4628	2508	35	5180	2516
C2L4	23	4423	2305	22	4635	2575	23	4860	2591
C6L2	7	5682	3006	8	5613	3085	7	5581	3096
C2L3	13	5507	3517	12	5907	3613	14	5717	3493
C2L4	21	5691	3340	20	5374	3049	21	5489	2906
C5L7	36	8340	6135	37	8104	5743	38	7449	4648
C2L6	35	8015	6720	35	7245	5721	35	7053	5464
C3L4	22	3972	3589	20	5448	3600	21	3828	2400
C4L1	3	4888	2216	3	5655	2854	3	5931	3567
C4L4	21	6575	3458	23	5450	2858	21	5698	2814
C6L3	16	5864	3975	16	5673	3755	16	5187	3297
C2L6	33	5929	4396	35	5546	4218	34	6404	5277
C4L7	38	5080	4380	36	6113	4308	37	4693	4289
C5L4	20	4873	3464	20	6601	5211	19	6243	4709
C6L5	25	5379	3020	27	5090	2973	27	4330	3134
C1L6	34	4680	2906	34	5039	3097	34	4509	2748
C3L5	27	5410	3931	27	5314	3605	27	5864	3579
C6L2	10	5544	3807	9	5300	3563	10	5160	3453
	35 segmentos com mistura Precisão: 66,8%			34 segmentos com mistura Precisão: 66,4%			34 segmentos com mistura Precisão: 67,6%		

4.2 Classificação

Esta seção está separada em recortes, referente aos 28 retângulos extraídos dos ortomosaicos, e área teste, que foi utilizada para a produção dos mapas de classificação, abrangendo a presença das três espécies de VAE e superfície d'água.

4.2.1 Recortes

Esta subseção contempla a seleção de atributos do GeoDMA e síntese dos descritores de textura SIFT, seguida pela sua classificação e dos diferentes conjuntos de dados, por fim, trata sobre a contribuição dos atributos para a discriminação das espécies de VAE.

4.2.1.1 Seleção de atributos do GeoDMA e síntese dos descritores de textura SIFT

Dentre os 20 atributos espectrais disponíveis por banda espectral (Tabela 5), foram selecionados 10 de cada uma, os quais foram elencados com acurácia a partir de 80%, totalizando-se 40 atributos espectrais selecionados (Tabela 9). Destaca-se ainda que o atributo selecionado, específico de uma banda, foi considerado para as demais bandas visto que em uma classificação preliminar, utilizando Random Forest, resultou em aproximadamente 10% a mais de acurácia do que selecionando atributos específicos de maior contribuição de cada banda, sem alterar significativamente o tempo de processamento.

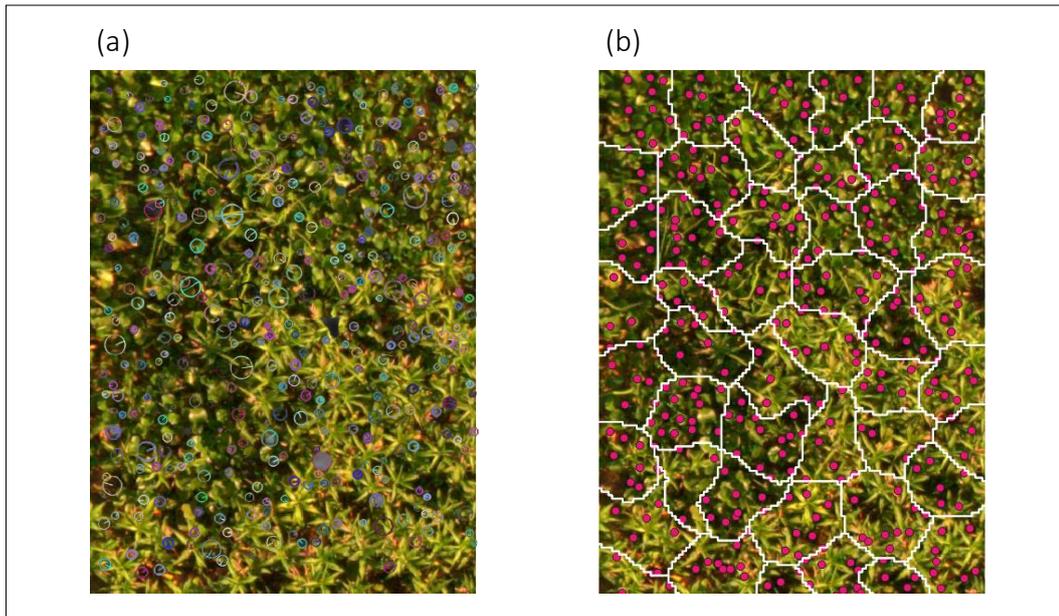
Tabela 9 - Os atributos selecionados do GeoDMA: 10 atributos de cada banda (azul, verde, vermelho e IVP), totalizando-se 40 atributos.

BANDA (λ)
AMPL_ λ
KURT_ λ
MAX_VAL_ λ
MEAN_ λ
MEDIAN_ λ
SKEW_ λ
VARCOEF_ λ
CONTSE_ λ
DISSE_ λ
ENTRSE_ λ

Quanto aos descritores de textura SIFT, para exemplificar a extração dos pontos-chave, a Figura 33a apresenta o recorte 1 (versão subamostrado para 3 cm) com a direção e magnitude

do gradiente, e a Figura 33b, a localização deles delimitados pelos segmentos, sendo que cada um engloba vários pontos-chave. A magnitude é representada pelo tamanho do círculo que, quanto maior, mais homogênea é a região. Assim como, quanto menor, mais heterogênea. Logo, a magnitude é um bom indicador do grau de heterogeneidade, que pode fornecer informações importantes sobre as características e particularidades de cada espécie.

Figura 33 - Extração de 499 pontos-chave do recorte 1 subamostrado para 3 cm. (a) Localização dos pontos-chave (b) delimitados pelos segmentos, que englobam vários deles. As duas figuras estão com o recorte original, para a melhor visualização.



O exemplo dado do recorte 1 subamostrado para 3 cm também vale para a subamostragem de 2 cm, o que muda é apenas a quantidade de pontos-chave. O recorte 1 corresponde a 499 pontos-chave (Figura 33), e a Tabela 10 mostra os valores internos de alguns dos vetores descritores (pontos-chave), que estão normalizados. Embora a Tabela 10 apresente valores de 0 (0,000000), esses valores são importantes e descrevem o entorno do ponto-chave. A Tabela 11, por sua vez, demonstra o procedimento do cálculo de coeficiente de variação, média e mediana para o segmento com identificador (ID) 0 do recorte 1 (localizado no canto superior esquerdo da Figura 33b), contendo 16 pontos-chave.

As versões subamostradas de 2 cm e 3 cm dos recortes foram utilizadas para extrair os pontos-chave e descritores, cada subamostragem gerou uma média diferente de pontos-chave dentre os 28 recortes, 1100 e 380, respectivamente. Empiricamente, foram selecionadas as subamostragens referidas porque a extração em níveis de GSD menores (0,8 cm, 1 cm e 1,6 cm) gerou uma quantidade de pontos-chave acima de 4000, e considerou-se que 2 cm e 3 cm

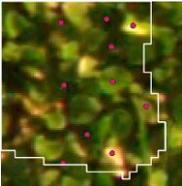
seriam suficientes para prosseguir com este estudo. As versões suavizadas dos recortes não foram empregadas nessa etapa, visto que não demonstraram ser tão consistentes para a detecção de textura quanto as versões subamostradas.

Tabela 10 - Valores internos dos vetores descritores (pontos-chave) obtidos por SIFT, referente à Figura 33.

		Posições internas dos vetores descritores						
		1	2	3	4	5	...	128
Pontos-chave	1	0,000175	0,000087	0,000175	0,000087	0,000087	...	0,003060
	2	0,000000	0,000000	0,000000	0,000000	0,000000	...	0,000874
	3	0,000087	0,000699	0,001049	0,004459	0,006733	...	0,000000
	4	0,000000	0,000000	0,000000	0,000000	0,000000	...	0,002448
	5	0,000000	0,000000	0,000000	0,000000	0,000000	...	0,000000

	499	0,000087	0,000525	0,004110	0,002885	0,002798	...	0,000000

Tabela 11 - Cálculo do coeficiente de variação, média e mediana dos descritores dos pontos-chave pertencentes a um mesmo segmento (ID 0), para a obtenção de um ponto-chave sintético do recorte 1 subamostrado para 3 cm.

		Posições internas dos vetores descritores					
		Ponto-chave	1	2	3	...	128
Pontos-chave		1	0,000087	0,000699	0,004022	...	0,002098
		2	0,003585	0,003323	0,010055	...	0,000000
		3	0,000262	0,000350	0,000000	...	0,000787
		4	0,002711	0,002973	0,003847	...	0,000000
		5	0,003497	0,000699	0,000350	...	0,001137
		6	0,000087	0,003410	0,005071	...	0,000000
		7	0,000087	0,000350	0,000000	...	0,000437
		8	0,000175	0,000612	0,001749	...	0,002011
		9	0,005596	0,002536	0,000874	...	0,001049
		10	0,000350	0,000787	0,000699	...	0,003148
		11	0,001574	0,000874	0,001574	...	0,003760
		12	0,000699	0,000087	0,000087	...	0,009181
		13	0,000175	0,000699	0,003585	...	0,002186
		14	0,001574	0,001574	0,002798	...	0,001224
		15	0,004197	0,003760	0,003935	...	0,000699
		16	0,003672	0,009356	0,003410	...	0,001574
Coeficiente de variação			1,035403	1,160173	0,991895	...	1,226374
Média			0,001771	0,002006	0,002629	...	0,001831
Mediana			0,001137	0,000831	0,002274	...	0,001181

4.2.1.2 Classificação dos descritores de textura SIFT

O desempenho da classificação dos descritores de textura SIFT para os 6 pontos-chave sintéticos, variando o número de árvores, encontra-se na Tabela 12 demonstrado pela acurácia global e coeficiente Kappa. Nota-se que os maiores valores condizem com o ponto-chave sintético 2cm_média em primeiro lugar, seguido por 2cm_mediana e 3cm_média, e os valores inferiores foram dos pontos-chave 3cm_mediana e aqueles sintetizados pelo coeficiente de variação.

Tabela 12 - Desempenho da classificação dos descritores de textura SIFT para os 6 pontos-chave sintéticos, variando o número de árvores, demonstrado pela Acurácia Global (AG) e Coeficiente Kappa (CK). O ponto-chave sintético com o maior desempenho (2cm_média) está em negrito.

Ponto-chave sintético	Nº de árvores									
	100		200		300		400		500	
	AG	CK	AG	CK	AG	CK	AG	CK	AG	CK
2cm_coef_var	67,27%	0,48	68,18%	0,50	66,82%	0,48	66,82%	0,48	66,82%	0,48
2cm_média	82,73%	0,73	84,09%	0,75	84,55%	0,76	83,64%	0,74	84,09%	0,75
2cm_mediana	77,73%	0,65	79,09%	0,67	80,45%	0,69	79,55%	0,68	79,55%	0,68
3cm_coef_var	59,55%	0,33	56,82%	0,28	55,00%	0,25	56,82%	0,28	55,91%	0,26
3cm_média	77,73%	0,65	77,73%	0,65	77,27%	0,64	77,73%	0,65	77,73%	0,65
3cm_mediana	72,73%	0,56	74,09%	0,58	73,64%	0,58	73,18%	0,57	73,64%	0,58

A Tabela 12 indica que a informação de textura é mais significativa conforme a resolução espacial aumenta, pois os três pontos-chave sintéticos de 2 cm apresentaram resultados melhores que os de 3 cm. A alta resolução espacial pode ser interpretada como ruído para alguns algoritmos de segmentação, mas é relevante para a textura, pois impactou diretamente no desempenho da classificação.

Comparando os três pontos-chave sintéticos, a média sintetizou os pontos-chave de cada segmento com maior consistência, seguida pela mediana e coeficiente de variação, que teve um desempenho inferior devido à falta de descritores de alguns segmentos na subamostragem de 3 cm. Nesse caso, a maioria dos segmentos contém em média 8 pontos-chave, porém alguns deles resultaram em somente 1 ponto-chave, assim, não foi possível calcular o desvio padrão, deixando o vetor dos 128 descritores de textura SIFT vazio. Para a subamostragem de 2 cm, o mesmo não ocorreu, visto que possui uma média de 20 pontos-chave por segmento e não resultou em segmentos com apenas 1 ponto-chave, mas obteve um baixo desempenho devido à própria variação dos dados, que ao invés de caracterizar o comportamento de cada classe temática, causou mais confusão.

A média e mediana são medidas estatísticas de tendência central que indicam um valor em torno do qual concentram-se os dados, enquanto o coeficiente de variação é uma medida de dispersão. Como os descritores de textura SIFT resultam em muitos valores, sintetizá-los pelas medidas de tendência central permitiu descrevê-los melhor, sobressaindo-se a média por levar em consideração todos os valores observados comparado a considerar unicamente o valor central (mediana). Logo, o ponto-chave sintético 2cm_média foi selecionado e integrado nos demais conjuntos de dados.

4.2.1.3 Classificação dos diferentes conjuntos de dados

O treinamento dos conjuntos de dados resultou no desempenho apresentado na Tabela 13. De acordo com o número de árvores testado, não é possível notar em nenhuma das tabelas (Tabelas 12 e 13) um padrão ou efeito perceptível do incremento do parâmetro. A acurácia não teve ganho significativo conforme o aumento do número de árvores, mas se observa que um valor intermediário de 300 árvores no Random Forest pode ser suficiente para a maioria dos conjuntos de dados da Tabela 13, visto que utilizar menos árvores é computacionalmente vantajoso, por ser mais rápido. Para 1, 2, 3, 4 e 8 o melhor desempenho foi com 300 árvores; para 5, 500 árvores; enquanto para 6 e 7, 100 árvores já seria suficiente, contudo, adotou-se 300 árvores para todos os conjuntos de dados, a fim de compará-los. A Tabela 14 mostra os valores de acurácia global e coeficiente Kappa das classificações.

Tabela 13 - Desempenho do treinamento dos diferentes conjuntos de dados utilizando Validação Cruzada, variando o número de árvores, descrito pela Acurácia Global (AG) e Coeficiente Kappa (CK). Os maiores valores de cada conjunto de dados estão em negrito.

Conjunto de dados	Nº de árvores									
	100		200		300		400		500	
	AG	CK	AG	CK	CK	AG	AG	CK	AG	CK
1	75,87%	0,62	75,78%	0,62	0,63	76,05%	75,78%	0,62	75,87%	0,62
2	81,44%	0,71	81,35%	0,71	0,72	81,90%	81,72%	0,72	81,90%	0,72
3	84,73%	0,76	84,37%	0,76	0,76	84,73%	84,28%	0,76	84,64%	0,76
4	87,39%	0,80	87,29%	0,80	0,81	87,75%	87,66%	0,81	87,39%	0,80
5	86,93%	0,80	87,48%	0,81	0,81	87,48%	87,57%	0,81	87,66%	0,81
6	87,84%	0,81	87,48%	0,81	0,81	87,75%	87,66%	0,81	87,75%	0,81
7	86,93%	0,80	86,56%	0,79	0,80	86,93%	86,56%	0,79	86,20%	0,79
8	87,75%	0,81	88,21%	0,82	0,82	88,48%	88,30%	0,82	88,30%	0,82

Exceto pelo conjunto de dados 1, o restante teve um desempenho acima de 90% de acurácia global e 0,80 de coeficiente Kappa. Apesar do desempenho inferior da classificação dos descritores de textura SIFT comparado às demais classificações, o resultado é relevante porque, em estudos similares, como realizado por Husson et al. (2016), as classificações produzidas resultaram em um intervalo de 52% a 69% de acurácia global e 0,34 a 0,54 de coeficiente Kappa, integrando atributos espectrais e de textura. E no caso do conjunto de dados 1, há apenas atributos de textura. As matrizes de confusão das classificações mais relevantes são apresentadas a seguir (Tabelas de 15 a 20).

Tabela 14 - Desempenho da classificação dos 8 conjuntos de dados, utilizando 300 árvores, descrito pela Acurácia Global e Coeficiente Kappa.

Conjunto de dados	Descrição	Acurácia Global	Coeficiente Kappa
1	Somente os descritores de textura SIFT	83,64%	0,74
2	Apenas os atributos de textura do GeoDMA (coeficiente de variação, contraste, dissimilaridade e entropia)	90,91%	0,86
3	Atributos espectrais do GeoDMA	92,73%	0,88
4	Atributos espectrais e de textura do GeoDMA	93,18%	0,89
5	Atributos espectrais e de textura do GeoDMA + índices de vegetação	93,64%	0,90
6	Atributos espectrais e de textura do GeoDMA + índices de vegetação + densidade de pontos	95%	0,92
7	Atributos espectrais do GeoDMA + descritores de textura SIFT	93,64%	0,90
8	Atributos espectrais e de textura do GeoDMA + índices de vegetação + densidade de pontos + descritores de textura SIFT	93,18%	0,89

Tabela 15 - Matriz de confusão calculada para a classificação do conjunto de dados 1 com 128 atributos (somente os descritores de textura SIFT). AG = Acurácia Global; CK = Coeficiente Kappa.

	Aguapé	Taboa	Erva-de-jacaré	Total	Acurácia do Usuário
Aguapé	88	5	1	94	93,62%
Taboa	3	66	4	73	90,41%
Erva-de-jacaré	14	9	30	53	56,60%
Total	105	80	35	220	
Acurácia do Produtor	83,81%	82,50%	85,71%		AG = 83,64% / CK = 0,74

A partir da matriz de confusão (Tabela 15), percebe-se que a acurácia do produtor é menor para as classes aguapé e taboa, indicando que o erro de omissão é maior, ou seja, segmentos que deveriam pertencer a elas foram atribuídos às classes incorretas. Para erva-de-jacaré, é o inverso, a acurácia do usuário é inferior, pois contém segmentos incorretos (falsos-positivos). O mesmo comportamento foi constatado na classificação do conjunto de dados 2 (atributos de textura do GeoDMA – Tabela 16), em ambos os casos são utilizados apenas atributos de textura. Mas para 1, a maior confusão ocorre entre erva-de-jacaré e aguapé devido

à detecção de textura similar, constatada pela discriminação do número de pontos-chave extraídos dos recortes de acordo com a(s) espécie(s) presente(s) na cena, atributo densidade de pontos – incluí-lo nas duas classificações mencionadas não melhorou o desempenho delas.

Tabela 16 - Matriz de confusão calculada para a classificação do conjunto de dados 2 com 16 atributos (apenas os atributos de textura do GeoDMA – coeficiente de variação, contraste, dissimilaridade e entropia). AG = Acurácia Global; CK = Coeficiente Kappa.

	Aguapé	Taboa	Erva-de-jacaré	Total	Acurácia do Usuário
Aguapé	92	2	0	94	97,87%
Taboa	2	66	5	73	90,41%
Erva-de-jacaré	2	9	42	53	79,25%
Total	96	77	47	220	
Acurácia do Produtor	95,83%	85,71%	89,36%		AG = 90,91% / CK = 0,86

Nota-se que a acurácia do produtor e usuário aumentaram para as três espécies, com exceção da acurácia do usuário para taboa, que foi mantido da classificação anterior, portanto, não foram acrescentados segmentos incorretos nessa classe. Assim, o desempenho da classificação utilizando 4 atributos de textura do GeoDMA de cada banda espectral foi superior aos 128 descritores de textura do SIFT.

A classificação com apenas atributos espectrais (conjunto de dados 3 – Tabela 17), sem os 4 atributos de textura do GeoDMA utilizados no conjunto de dados 2, resultou em um desempenho superior. A acurácia do produtor para taboa aumentou consideravelmente (7,15%), o que significa que incluiu menos segmentos incorretos nessa classe, assim como a acurácia do usuário para erva-de-jacaré teve um acréscimo de 11,32%, diminuindo os erros de comissão em relação aos conjuntos de dados anteriores. Os atributos espectrais foram muito importantes para discernir erva-de-jacaré das outras espécies.

Tabela 17 - Matriz de confusão calculada para a classificação do conjunto de dados 3 com 24 atributos (atributos espectrais do GeoDMA). AG = Acurácia Global; CK = Coeficiente Kappa.

	Aguapé	Taboa	Erva-de-jacaré	Total	Acurácia do Usuário
Aguapé	91	3	0	94	96,81%
Taboa	3	65	5	73	89,04%
Erva-de-jacaré	3	2	48	53	90,57%
Total	97	70	53	220	
Acurácia do Produtor	93,81%	92,86%	90,57%		AG = 92,73% / CK = 0,88

Quando os atributos de textura do GeoDMA são retirados do conjunto de dados 3, os índices de vegetação e a densidade de pontos são adicionados gradualmente, a acurácia melhora gradativamente conforme os novos atributos são incorporados, culminando na classificação do conjunto de dados 6 com o melhor desempenho, 95% de acurácia global e 0,92 de coeficiente

Kappa (Tabela 18). As matrizes de confusão dos conjuntos de dados 4 e 5 foram omitidas porque são as classificações intermediárias até 6, além disso, as acurácias do produtor e usuário de todas as classificações estão resumidas na Tabela 23.

Tabela 18 - Matriz de confusão calculada para a classificação do conjunto de dados 6 com 43 atributos (atributos espectrais e de textura do GeoDMA, índices de vegetação e densidade de pontos). AG = Acurácia Global; CK = Coeficiente Kappa.

	Aguapé	Taboa	Erva-de-jacaré	Total	Acurácia do Usuário
Aguapé	91	3	0	94	96,81%
Taboa	2	71	0	73	97,26%
Erva-de-jacaré	4	2	47	53	88,68%
Total	97	76	47	220	
Acurácia do Produtor	93,81%	93,42%	100%		AG = 95% / CK = 0,92

Em relação ao conjunto de dados 3, as acurácias do produtor e usuário foram mantidas para aguapé, aumentou 0,56% e 8,22%, respectivamente, para taboa; e erva-de-jacaré obteve 100% de acurácia do produtor e a acurácia do usuário diminuiu 1,89%. Logo, não foram introduzidos erros na classe aguapé, o desempenho da classe taboa melhorou e não houve erros de omissão na classe erva-de-jacaré.

Ao classificar apenas os atributos espectrais obteve-se uma acurácia global de 92,73%, adicionando-se os atributos de textura do GeoDMA esse valor aumentou em 0,45% (conjunto de dados 4 – 93,18%), incluindo os índices de vegetação, mais 0,46% (conjunto de dados 5 – 93,64%), por fim, ao inserir a densidade de pontos o acréscimo foi de mais 1,36% (conjunto de dados 6 – 95%), sendo o atributo que mais contribuiu para o aumento da acurácia global. Analogamente, os descritores de textura SIFT foram adicionados aos atributos espectrais (conjunto de dados 7 – Tabela 20), ao invés dos atributos de textura do GeoDMA, e gradualmente adicionadas as mesmas camadas mencionadas. Com a informação de textura, a acurácia global aumentou 0,91% (93,64%), com os índices de vegetação, diminuiu 0,91% (92,73%), e ao incorporar a densidade de pontos, aumentou 0,45% (93,18%), mas ainda obteve um desempenho inferior à classificação inicial, que utilizou apenas os atributos espectrais com os descritores de textura SIFT (93,64%). Essas comparações estão compiladas na Tabela 19.

Tabela 19 - Comparação das classificações considerando os atributos de textura do GeoDMA com os do SIFT, adicionando os demais atributos gradualmente. O atributo densidade de pontos foi o que mais contribuiu para o aumento da acurácia global, destacado em negrito.

Atributos de textura – GeoDMA	Atributos de textura – descritores de textura SIFT
Atributos espectrais: acurácia global de 92,73%	Atributos espectrais: acurácia global de 92,73%
Atributos espectrais + atributos de textura: acurácia global de 93,18% (+0,45%)	Atributos espectrais + atributos de textura: acurácia global de 93,64% (+0,91%)
Atributos espectrais + atributos de textura + índices espectrais: acurácia global de 93,64% (+0,46%)	Atributos espectrais + atributos de textura + índices espectrais: acurácia global de 92,73% (-0,91%)
Atributos espectrais + atributos de textura + índices espectrais + densidade de pontos: acurácia global de 95% (+1,36%)	Atributos espectrais + atributos de textura + índices espectrais + densidade de pontos: acurácia global de 93,18% (+0,45%)

Tabela 20 - Matriz de confusão calculada para a classificação do conjunto de dados 7 com 152 atributos (atributos espectrais do GeoDMA e descritores de textura SIFT). AG = Acurácia Global; CK = Coeficiente Kappa.

	Aguapé	Taboa	Erva-de-jacaré	Total	Acurácia do Usuário
Aguapé	94	0	0	94	100%
Taboa	1	66	6	73	90,41%
Erva-de-jacaré	4	3	46	53	86,79%
Total	99	69	52	220	
Acurácia do Produtor	94,95%	95,65%	88,46%		AG = 93,64% / CK = 0,90

O conjunto de dados 8 (Tabela 21) integra todos os atributos, verificando-se que utilizar todos os atributos não garante uma classificação mais acurada, sendo a acurácia global e o coeficiente Kappa equivalentes à classificação dos atributos espectrais com os atributos de textura do GeoDMA (conjunto de dados 4).

Tabela 21 - Matriz de confusão calculada para a classificação do conjunto de dados 8 com 171 atributos (atributos espectrais e de textura do GeoDMA, índices de vegetação, densidade de pontos, e descritores de textura SIFT). AG = Acurácia Global; CK = Coeficiente Kappa.

	Aguapé	Taboa	Erva-de-jacaré	Total	Acurácia do Usuário
Aguapé	94	0	0	94	100%
Taboa	3	65	5	73	89,04%
Erva-de-jacaré	4	3	46	53	86,79%
Total	101	68	51		
Acurácia do Produtor	93,07%	95,59%	90,20%		AG = 93,18% / CK = 0,89

Quanto às classes temáticas, de forma geral em todas as classificações a acurácia do usuário foi maior para aguapé, enquanto para taboa e erva-de-jacaré a acurácia do produtor foi superior, ou seja, essas duas classes tiveram menos omissões comparado à aguapé que, por sua vez, teve menos erros de comissão (inclusão de segmentos de outras classes).

4.2.1.4 Contribuição dos atributos para a discriminação das espécies de VAE

O atributo densidade de pontos teve como intuito explorar o número de pontos-chave como potencial indicador da característica das espécies de VAE. Para esse atributo, foram utilizados os pontos-chave extraídos dos recortes subamostrados para 2 cm. A Tabela 22 apresenta o número de pontos por recorte com a especificação das espécies presentes, sendo possível observar que os recortes contendo apenas taboa são os que apontam a menor quantidade de pontos, enquanto erva-de-jacaré é intermediária, mas bem similar ao aguapé, que apresenta a média de maior número de pontos.

Tabela 22 - Número de pontos por recorte com a especificação das espécies presentes.

Recorte	Densidade de pontos	Conteúdo	Recorte	Densidade de pontos	Conteúdo
1	1237	aguapé e erva-de-jacaré	15	1380	aguapé e taboa
2	1098	aguapé e taboa	16	1197	erva-de-jacaré e taboa
3	1206	erva-de-jacaré e taboa	17	1294	aguapé
4	1299	aguapé	18	1566	aguapé
5	1550	aguapé	19	1083	aguapé e taboa
6	1016	aguapé e taboa	20	886	aguapé e taboa
7	1158	erva-de-jacaré	21	713	taboa
8	1298	erva-de-jacaré	22	1040	erva-de-jacaré
9	1284	erva-de-jacaré e taboa	23	1144	aguapé e taboa
10	1056	aguapé, taboa e erva-de-jacaré	24	977	erva-de-jacaré e taboa
11	948	taboa	25	983	erva-de-jacaré
12	816	taboa	26	815	aguapé e taboa
13	1340	aguapé e taboa	27	765	taboa
14	1028	aguapé e taboa	28	1103	aguapé e taboa

A Tabela 23 apresenta de forma sucinta as acurácias do produtor e usuário de todos os conjuntos de dados. Para aguapé, a maior acurácia do produtor pertence ao conjunto de dados 2 (atributos de textura do GeoDMA), indicando que atributos de textura são fundamentais na sua discriminação e diminuição dos erros de omissão, com um desempenho de 2,02% a mais do que utilizando apenas atributos espectrais (conjunto de dados 3), e seriam suficientes para esse caso. Em segundo lugar, encontra-se o conjunto de dados 7, no qual atributos espectrais e descritores SIFT foram combinados e mostraram-se uma combinação promissora também, com 1,14% e 11,14% de acréscimo em relação aos conjuntos de dados 3 e 1, respectivamente, utilizando esses atributos isoladamente. Quanto à acurácia do usuário, os conjuntos de dados 7 e 8 conseguiram eliminar 100% os erros de comissão, os quais contêm informações de textura e acrescentam 3,19% ao conjunto de dados 3, que utiliza apenas atributos espectrais.

Tabela 23 - S mula das acur cias do produtor e usu rio da classifica o de todos os conjuntos de dados.

Conjunto de dados	Acur�cia do Produtor							
	1	2	3	4	5	6	7	8
Classes								
Aguap�	83,81%	95,83%	93,81%	92,86%	93,88%	93,81%	94,95%	93,07%
Taboa	82,50%	85,71%	92,86%	94,29%	94,37%	93,42%	95,65%	95,59%
Erva-de-jacar�	85,71%	89,36%	90,57%	92,31%	92,16%	100%	88,46%	90,20%

Conjunto de dados	Acur�cia do Usu�rio							
	1	2	3	4	5	6	7	8
Classes								
Aguap�	93,62%	97,87%	96,81%	96,81%	97,87%	96,81%	100%	100%
Taboa	90,41%	90,41%	89,04%	90,41%	91,78%	97,26%	90,41%	89,04%
Erva-de-jacar�	56,60%	79,25%	90,57%	90,57%	88,68%	88,68%	86,79%	86,79%

Para taboa, tanto a acur cia do produtor quanto a acur cia do usu rio mostram que somente atributos de textura (conjuntos de dados 1 e 2) ou espectrais (conjunto de dados 3) podem n o ser t o consistentes para bem caracteriz -las quando separados, mas, quando integrados, o desempenho   superior. Ao combinar atributos espectrais com descritores de textura SIFT (conjunto de dados 7), a acur cia do produtor admite um aumento de 2,83%. Analogamente, a acur cia do usu rio sobe 8,22% integrando os atributos de textura do GeoDMA (conjunto de dados 6).

Similar   classe taboa, a acur cia do produtor da erva-de-jacar  revela que os atributos espectrais e de textura quando empregados de forma integrada resultam em um desempenho melhor do que separados, com um aumento de 9,43% do conjunto de dados 3 para o 6. A acur cia do usu rio, por sua vez, apontou que os atributos espectrais (conjunto de dados 3) podem ser suficientes para reduzir o erro de comiss o, todavia, quando incorporados aos atributos de textura do GeoDMA, t m s o prop cios para discriminar erva-de-jacar  (conjunto de dados 4).

Quanto   inclus o dos atributos de textura,  ndices de vegeta o e densidade de pontos, camada por camada, aos atributos espectrais, a Tabela 24 faz um comparativo dessas incorpora es em rela o aos atributos de textura do GeoDMA e os descritores de textura SIFT, cujas adi es graduais n o foram consideradas nos conjuntos de dados em raz o das acur cias globais serem menores, mantendo-se apenas a classifica o de maior desempenho (atributos espectrais com descritores de textura SIFT – conjunto de dados 7).

Tabela 24 - Comparativo da incorporação de atributos de textura do GeoDMA e descritores de textura SIFT, índices de vegetação e densidade de pontos, camada por camada, aos atributos espectrais. AE = atributos espectrais; AT = atributos de textura; IV = índices de vegetação; DP = densidade de pontos.

Atributos de textura do GeoDMA					Descritores de textura SIFT			
Conjunto de dados Classes	Acurácia do Produtor				Acurácia do Usuário			
	AE	AE+AT	AE+AT+ IV	AE+AT+ IV+DP	AE	AE+AT	AE+AT+ IV	AE+AT+ IV+DP
Nº de atributos	24	40	42	43	24	152	154	155
Aguapé	93,81%	92,86%	93,88%	93,81%	93,81%	94,95%	93,07%	93,07%
Taboa	92,86%	94,29%	94,37%	93,42%	92,86%	95,65%	94,12%	95,59%
Erva-de-jacaré	90,57%	92,31%	92,16%	100%	90,57%	88,46%	90,20%	90,20%
Nº de atributos	24	40	42	43	24	152	154	155
Aguapé	96,81%	96,81%	97,87%	96,81%	96,81%	100%	100%	100%
Taboa	89,04%	90,41%	91,78%	97,26%	89,04%	90,41%	87,67%	89,04%
Erva-de-jacaré	90,57%	90,57%	88,68%	88,68%	90,57%	86,79%	86,79%	86,79%

A textura do GeoDMA aumentou as acurácias das espécies taboa e erva-de-jacaré, a qual manteve o valor de acurácia do usuário. Enquanto a textura SIFT aumentou as acurácias de aguapé e taboa, e diminuiu as de erva-de-jacaré, que não parece descrevê-la de forma tão satisfatória como as outras. Os índices de vegetação contribuíram para um aumento na média de 0,9% das acurácias de aguapé e taboa acrescidos aos atributos espectrais e de textura do GeoDMA. Quando adicionados aos atributos espectrais com os descritores de textura SIFT, melhoraram apenas a acurácia do produtor da erva-de-jacaré, em 1,74%. Por fim, a camada de densidade de pontos, contribuiu para o desempenho da taboa nos dois casos, GeoDMA e SIFT, e para a erva-de-jacaré, no GeoDMA. Como o atributo mencionado é parte da textura SIFT, espera-se que a contribuição seja menor para esse caso.

Em suma, os índices de vegetação e densidade de pontos contribuíram mais para os atributos espectrais e de textura do GeoDMA do que para os atributos espectrais combinados com os descritores de textura SIFT, por isso o conjunto de dados 6 resultou em uma acurácia global superior aos demais. Contudo, comparando-se as duas procedências de textura, os descritores de textura SIFT contribuíram significativamente mais que os atributos de textura do GeoDMA para o aumento das acurácias no caso [atributos espectrais (AE) + atributos de textura (AT)].

As características espectrais das espécies de VAE são essenciais na classificação, mas adicionar outros atributos também é importante para refinar o desempenho. Em relação à textura, evidenciou-se que as duas procedências, GeoDMA e SIFT, são de grande relevância na discriminação das espécies de VAE. Vale ressaltar ainda que Haralick et al. (1973) baseiam-se na suposição que a informação de textura em uma imagem está contida na relação espacial

média que os tons de cinza têm entre si, portanto, parte da informação de textura já pode estar contida intrinsecamente nos atributos espectrais, uma vez que a abordagem de classificação é OBIA, utilizando os segmentos (objetos) como unidade de análise.

Para os recortes, a acurácia global e coeficiente Kappa das classificações, em sua maioria, são contemplados pelo intervalo de 89% a 95%, e 0,88 a 0,93, respectivamente, valores encontrados na literatura em estudos similares de classificações mais acuradas (CHABOT et al., 2018; BENJAMIN et al., 2021; BOLCH et al., 2021; ZHOU et al., 2021). Apenas os dois primeiros conjuntos de dados, que utilizam somente atributos de textura, ficariam fora desses intervalos, sendo que os estudos mencionados incluíram atributos de textura e confirmaram a sua importância, mas não foram empregados isoladamente.

4.2.2 Área teste – mapa de classificação

A área teste foi classificada para os 8 conjuntos de dados, utilizando o conjunto de treinamento dos 28 recortes e mantendo o número de árvores elencado anteriormente, que resultou no desempenho especificado na Tabela 25. No estudo desenvolvido por Husson et al. (2016), as classificações resultaram em um intervalo de 52% a 69% de acurácia global e 0,34 a 0,54 de coeficiente Kappa, enquanto outros estudos similares de classificações mais acuradas, como mencionado, variaram de 89% a 95%, e de 0,88 a 0,93, respectivamente (CHABOT et al., 2018; BENJAMIN et al., 2021; BOLCH et al., 2021; ZHOU et al., 2021). O desempenho da área teste encontra-se em um intervalo intermediário entre os estudos referidos.

Tabela 25 - Desempenho da classificação da área teste para os 8 conjuntos de dados.

Conjunto de dados	Descrição	Acurácia Global	Coefficiente Kappa
1	Somente os descritores de textura SIFT	59,01%	-
2	Apenas os atributos de textura do GeoDMA (coeficiente de variação, contraste, dissimilaridade e entropia)	77,79%	0,62
3	Atributos espectrais do GeoDMA	83,45%	0,69
4	Atributos espectrais e de textura do GeoDMA	84,93%	0,73
5	Atributos espectrais e de textura do GeoDMA + índices de vegetação	83,26%	0,69
6	Atributos espectrais e de textura do GeoDMA + índices de vegetação + densidade de pontos	84,97%	0,74
7	Atributos espectrais do GeoDMA + descritores de textura SIFT	79,79%	0,63
8	Atributos espectrais e de textura do GeoDMA + índices de vegetação + densidade de pontos + descritores de textura SIFT	80,65%	0,65

Os dois primeiros conjuntos de dados consistem apenas em atributos de textura, e são as classificações de menor desempenho. A Tabela 26 apresenta de forma sucinta as acurácias do produtor e usuário para todas as classificações, sendo possível constatar que o conjunto de dados 1 classificou de forma inconsistente, pois alocou todos os segmentos à classe aguapé, impossibilitando determinar o coeficiente Kappa, já o conjunto de dados 2 conseguiu identificar a existência das três classes temáticas.

Tabela 26 - Súmula das acurácias do produtor e usuário da classificação de todos os conjuntos de dados para a área teste.

	Acurácia do Produtor	Acurácia do Usuário
Conjunto de dados 1		
Aguapé	59,01%	100,00%
Taboa	-	0,00%
Erva-de-jacaré	-	0,00%
Conjunto de dados 2		
Aguapé	89,96%	83,72%
Taboa	67,50%	71,56%
Erva-de-jacaré	56,36%	65,56%
Conjunto de dados 3		
Aguapé	88,09%	92,99%
Taboa	71,21%	77,78%
Erva-de-jacaré	88,26%	56,80%
Conjunto de dados 4		
Aguapé	92,04%	89,44%
Taboa	75,22%	81,73%
Erva-de-jacaré	75,63%	73,11%
Conjunto de dados 5		
Aguapé	87,80%	92,83%
Taboa	70,78%	76,65%
Erva-de-jacaré	88,89%	58,01%
Conjunto de dados 6		
Aguapé	92,92%	89,93%
Taboa	73,34%	83,43%
Erva-de-jacaré	76,51%	68,88%
Conjunto de dados 7		
Aguapé	86,36%	90,33%
Taboa	69,22%	66,48%
Erva-de-jacaré	69,15%	61,63%
Conjunto de dados 8		
Aguapé	86,82%	89,20%
Taboa	67,80%	71,37%
Erva-de-jacaré	78,07%	63,44%

A partir da Tabela 26, é possível observar que em todos os conjuntos de dados as maiores acurácias, em sua maioria, pertencem à classe aguapé, o que também ocorre nos

recortes. A distribuição desigual das espécies de VAE na porção imageada do reservatório limitou trabalhar com recortes maiores, como, a área teste, pois as classes ficariam ainda mais desbalanceadas.

Como foi utilizado o mesmo conjunto de treinamento dos recortes, ao classificar a área teste a proporção de aguapé é maior que a dos recortes, assim como é menor para taboa e erva-de-jacaré, o que justifica a obtenção de acurácias menores. Para balanceá-las e obter acurácias maiores, seria necessário montar um novo conjunto de dados de treinamento baseado na proporção de ocorrência das espécies na área teste, mas isso não foi feito, visto que a intenção foi testar e desse teste gerar os mapas de classificação. Além disso, tal comportamento também está atrelado ao desbalanceamento entre classes devido à própria natureza da ocorrência das espécies no ambiente em que elas estão inseridas. Espera-se que confusões existam, ainda mais em locais de zona de transição entre uma espécie e outra, onde estão emaranhadas entre si e é difícil discerni-las.

São apresentados, a seguir, os mapas de classificação considerados mais relevantes, de acordo com a composição do conjunto de dados e respectiva acurácia global. Vale ressaltar que a área teste abrange uma área que contém 7 recortes, então alguns segmentos são repetidos dos dados de treinamento e validação.

Para ilustrar, o mapa de classificação do conjunto de dados 1 (Figura 34) mostra as classes água e aguapé dividida em segmentos, sendo possível notar o próprio comportamento distinto da segmentação para a região de água, os segmentos ficam totalmente rígidos e regulares, modificando sua forma nas margens, ao aproximar-se da VAE. Na Figura 35 as classes estão dissolvidas, como serão apresentadas para os demais mapas de classificação.

Figura 34 - Mapa de classificação para o conjunto de dados 1 (descritores de textura SIFT), exibido com as classes divididas em segmentos.

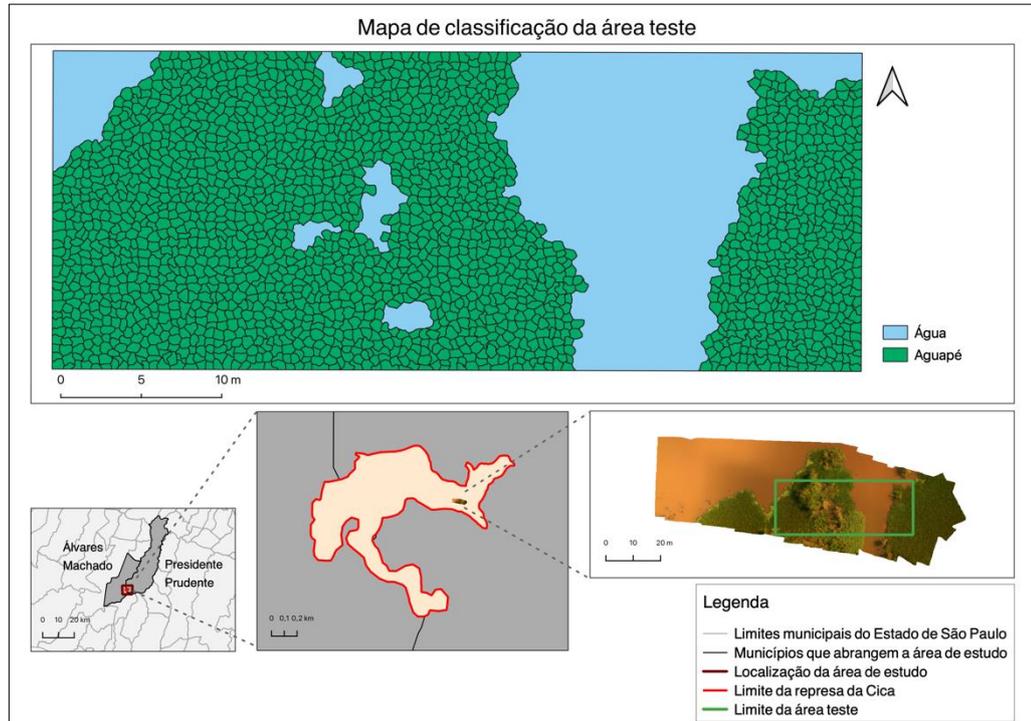
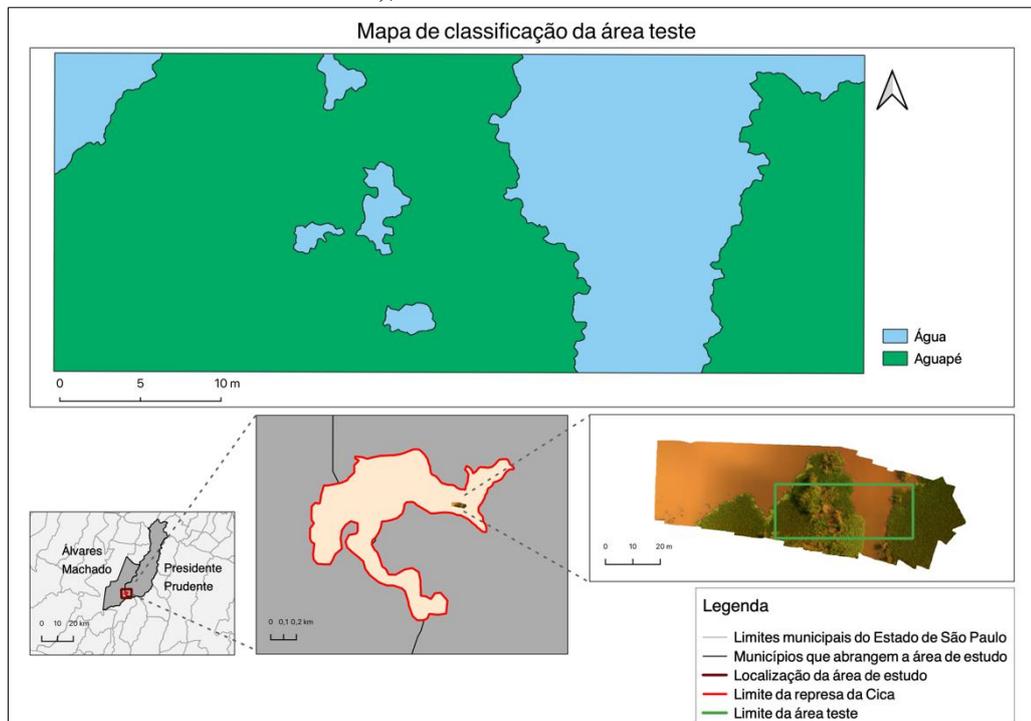


Figura 35 - Mapa de classificação para o conjunto de dados 1 (descritores de textura SIFT), exibido com as classes dissolvidas.

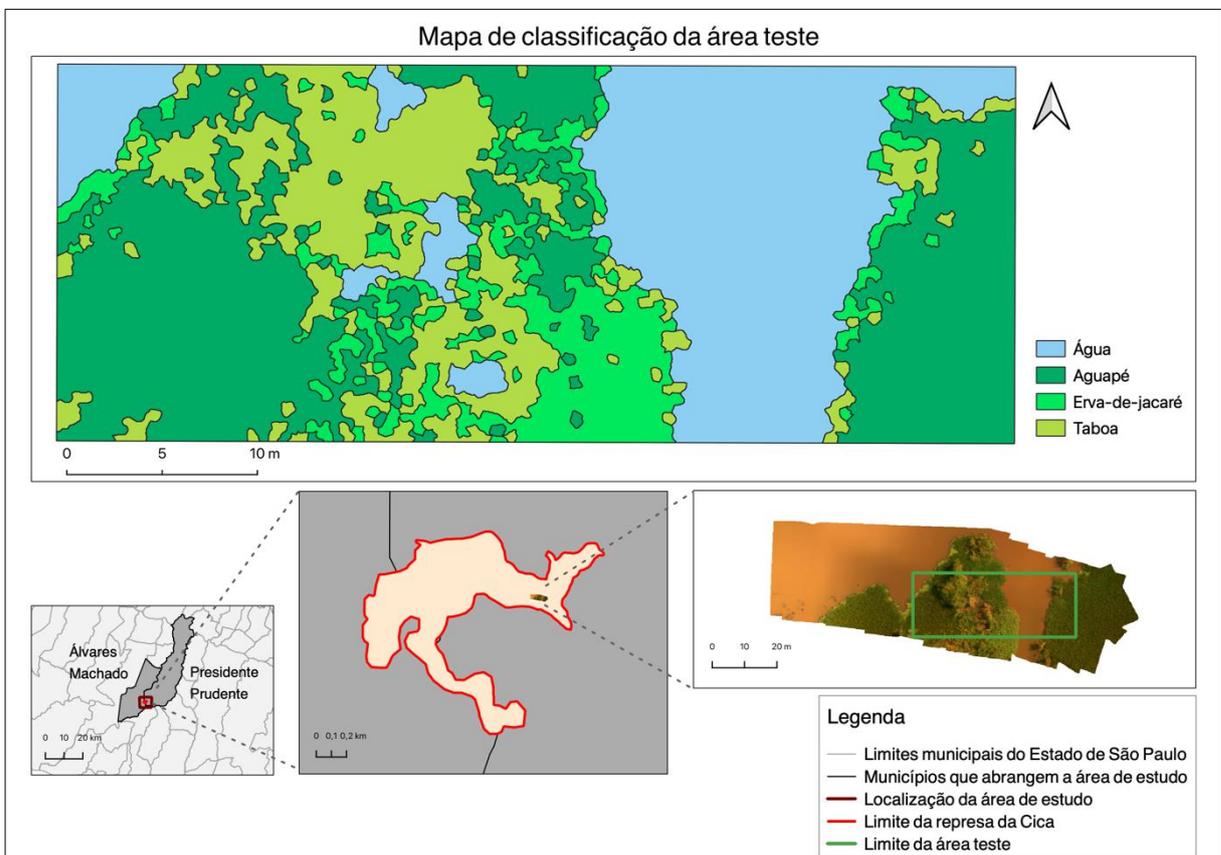


Para obter a mesma quantidade de segmentos em conformidade com os recortes, foi calculada a proporção comparando o tamanho dos recortes (450 pixels de largura e 600 pixels

de altura) com o tamanho da área teste (6202 pixels de largura e 2638 pixels de altura), levando em conta a média de 48 segmentos por recorte, resultou em 3005 segmentos.

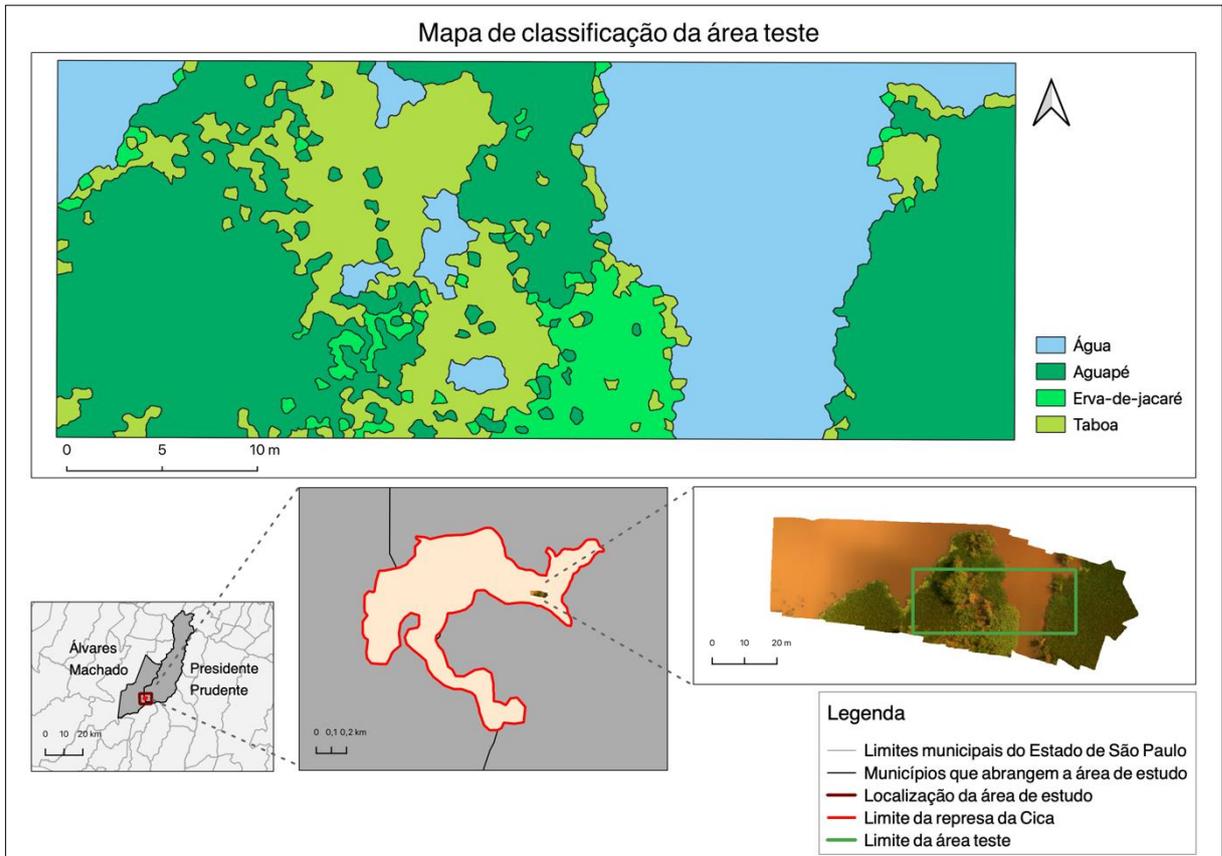
Como é possível verificar na Figura 35, o conjunto de dados 1 classificou erroneamente a área teste, ignorando a diversidade de espécies de VAE. Os descritores de textura SIFT, isolados, não conseguiram discerni-las nesse caso, o problema recai no conjunto de dados de treinamento que não foi representativo para a cena classificada. Por sua vez, o uso de atributos de textura do GeoDMA (conjunto de dados 2) aumentou a acurácia global em 18,78% comparado aos descritores de textura SIFT, contemplando as três classes temáticas (Figura 36).

Figura 36 - Mapa de classificação para o conjunto de dados 2 (atributos de textura do GeoDMA).



Apesar da acurácia global relativamente baixa (77,79%), o resultado é substancialmente superior ao conjunto de dados 1. Mas visualmente é perceptível que, para uma classificação mais acurada, como, o conjunto de dados 3 com 83,45% de acurácia global (Figura 37), há menos mistura na região de aguapé no meio da cena, assim como para erva-de-jacaré no mesmo local um pouco abaixo.

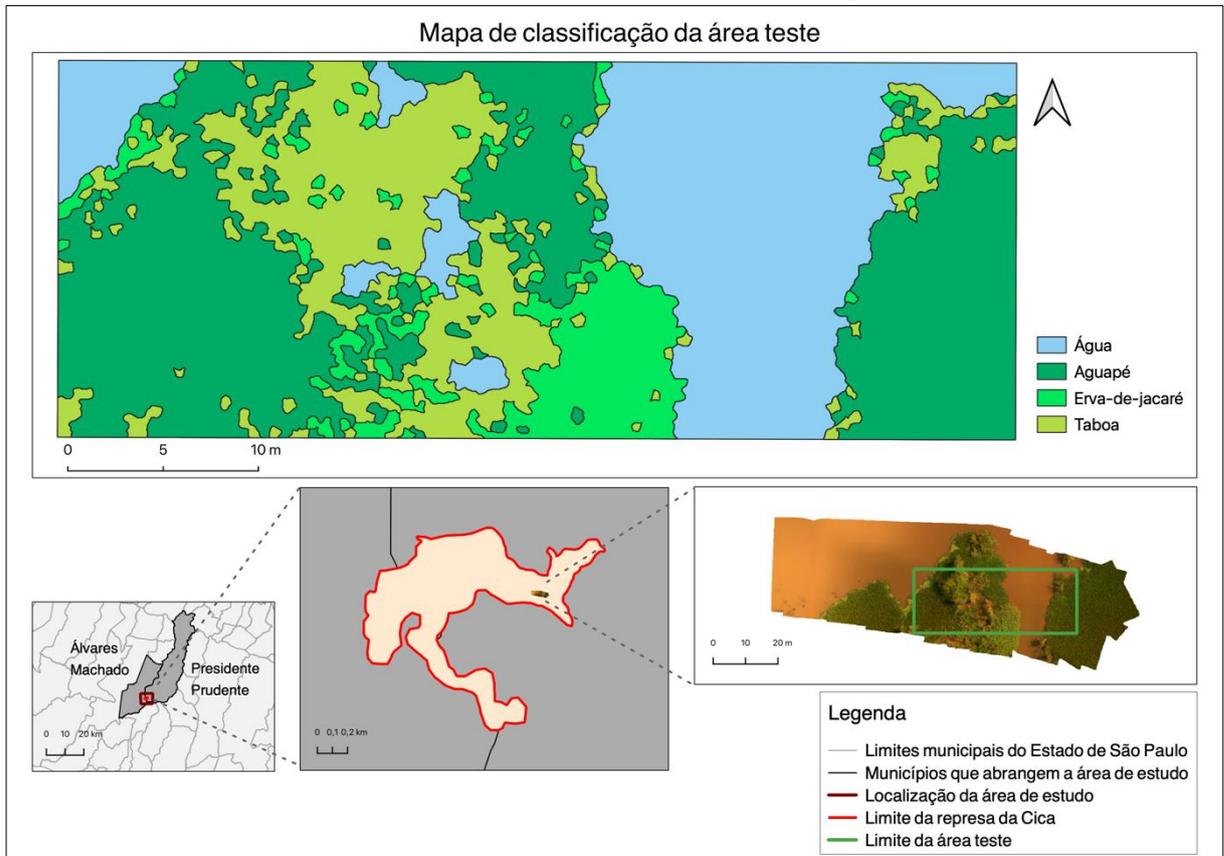
Figura 37 - Mapa de classificação para o conjunto de dados 3 (atributos espectrais do GeoDMA).



Entre o conjunto de dados 3, atributos espectrais do GeoDMA, e o conjunto de dados 5, acrescentando os atributos de textura e os índices de vegetação ao anterior, o conjunto de dados 3 obteve 0,19% a mais de acurácia global, então optou-se por mostrar apenas a classificação mais acurada. O mesmo aconteceu entre o conjunto de dados 4 e 6, a diferença é de apenas 0,04%, portanto, apenas a classificação de maior desempenho (conjunto de dados 6) foi apresentada (Figura 38). Como os conjuntos de dados 7 e 8 possuem acurácia global inferior ao 6, seus mapas de classificação não foram exibidos.

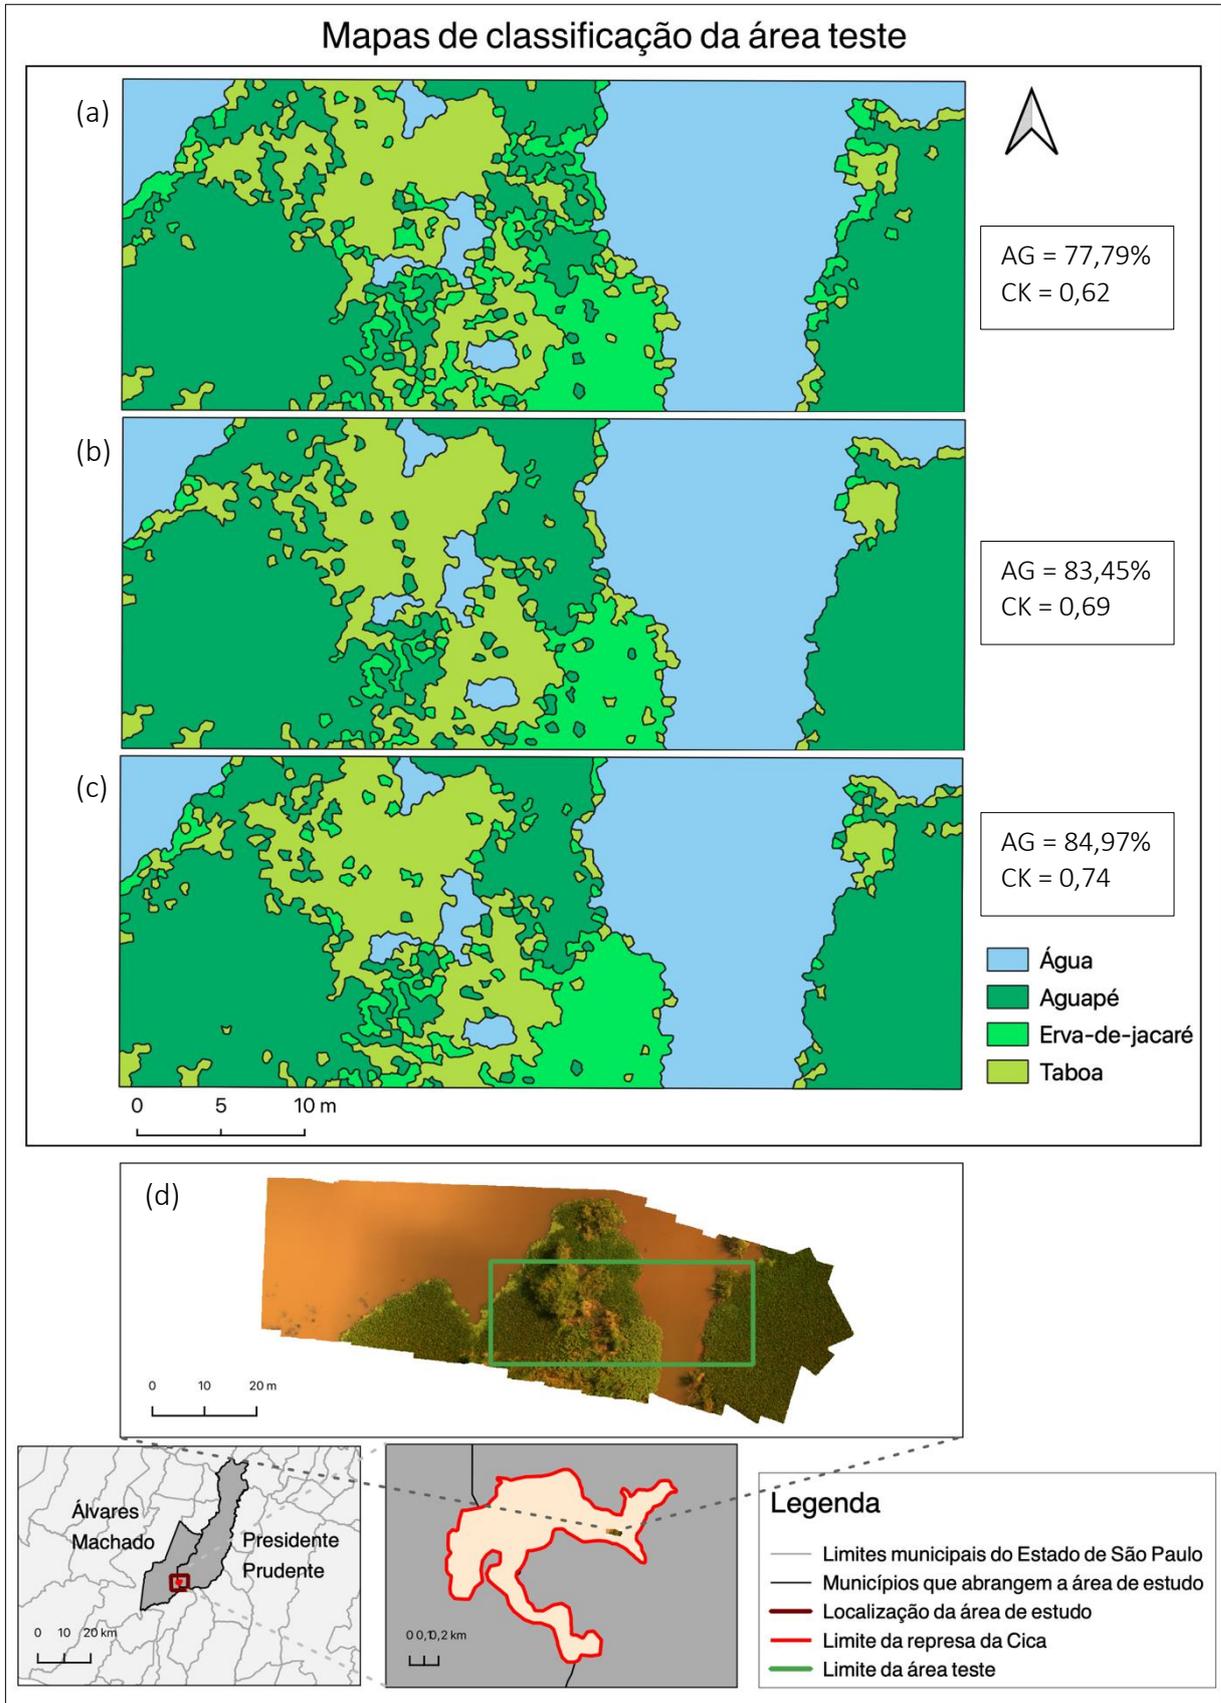
O conjunto de dados 6 obteve o maior desempenho para a área teste, condizente com os recortes, seguido pelo conjunto de dados 4. Em comparação com o conjunto de dados 3, apresentado anteriormente (Figura 37), visualmente as mudanças não são muito perceptíveis, mas os erros de omissões para aguapé e taboa diminuíram, bem como os erros de comissão para taboa e erva-de-jacaré.

Figura 38 - Mapa de classificação para o conjunto de dados 6 (atributos espectrais e de textura do GeodMA, índices de vegetação e densidade de pontos).



A Figura 39 mostra os três mapas de classificação apresentados com a área teste, que contemplaram a diversidade de espécies (conjunto de dados 2, 3 e 6), para facilitar a comparação visual. Nota-se que o aumento da acurácia das classificações melhora visualmente o discernimento entre as classes de VAE.

Figura 39 - Comparação da classificação dos conjuntos de dados (a) 2, (b) 3 e (c) 6 da (d) área teste. AG = Acurácia Global; CK = Coeficiente Kappa.



5 CONCLUSÕES

Os resultados obtidos dos três algoritmos de segmentação mostraram que Crescimento de Regiões e Watershed são os mais sensíveis à alta resolução espacial, sendo a super-segmentação uma das limitações de Watershed, que produziu a maior quantidade de segmentos. Dentre os três, o algoritmo Superpixel foi selecionado, combinando-se a abordagem da subamostragem e suavização, pois produziu segmentos que englobam a cobertura de uma mesma espécie de VAE, de forma a representar suas variações espectrais e de textura, e possibilitando diferenciá-la das demais espécies.

A alta resolução espacial foi um fator limitante para o comportamento dos algoritmos de segmentação Crescimento de Regiões e, principalmente, Watershed, mas constatou-se muito relevante para a textura, uma vez que um nível maior de detalhe, subamostragem de 2 cm, resultou em um desempenho de classificação dos descritores SIFT superior à subamostragem de 3 cm. Dessa forma, a análise da textura tem melhor desempenho em imagens não suavizadas. A suavização foi um procedimento importante para a etapa da segmentação, no entanto, o alto nível de detalhamento da imagem é determinante para a detecção de textura. Em suma, a subamostragem é adequada para a extração de textura, enquanto a suavização produz uma imagem melhor para a segmentação.

Ainda considerando os resultados obtidos da segmentação, é importante ressaltar também que o excesso de detalhes da cena, devido à alta resolução espacial, pode interferir na identificação da biodiversidade das espécies de VAE. Logo, o elevado nível de detalhamento deve ser ajustado, uma vez que para a segmentação pode ser um obstáculo ao passo que para a detecção de textura é fundamental, por isso, a importância das simulações e variações de grau de detalhe espacial.

Em relação à classificação, de forma geral, os resultados alcançados revelaram que os atributos de textura são importantes na discriminação de espécies de VAE, independente da procedência. Classificar apenas com atributos de textura resultou em acurácias menores, mas ainda assim significativas, indicando que a informação de textura por si só consegue explicar parte das características intrínsecas de cada espécie.

No caso da textura SIFT, o desempenho foi inferior em relação às texturas usualmente empregadas, como aquelas extraídas pela GLCM, obtidas por meio da ferramenta GeoDMA. Contudo, é relevante destacar que, dentre as três versões sintéticas dos pontos-chaves, as medidas de tendência central, média e mediana, conseguiram representar de forma mais satisfatória os descritores, resultando em classificações mais acuradas. Ainda, destaca-se que a

partir da integração do atributo denominado densidade de pontos, notou-se que a própria distribuição dos pontos-chave pode ser um bom indicador das características das espécies de VAE.

A integração de densidade de pontos e índices espectrais de vegetação aos atributos espectrais e de textura do GeoDMA contribuiu para o aumento da acurácia das classificações, o que não aconteceu ao incorporá-los aos atributos espectrais combinados com os descritores de textura SIFT, pois a densidade de pontos já é parte dessa textura. No entanto, os descritores de textura SIFT contribuíram consideravelmente mais que os atributos de textura do GeoDMA para o aumento das acurácias das classificações ao acrescentá-los aos atributos espectrais. Ao final, a combinação de atributos espectrais e de textura do GeoDMA, índices de vegetação e densidade de pontos foi o que gerou a maior acurácia global e coeficiente Kappa para a classificação dos recortes, 95% e 0,92, e área teste, 84,97% e 0,74, respectivamente.

Vale ressaltar que os atributos espectrais extraídos de cada segmento, pela abordagem OBIA, podem já conter parte da informação de textura e por isso incorporar atributos adicionais de textura não teve um ganho mais significativo de acurácia. Em relação as duas procedências de textura, quando classificados isoladamente, os atributos de textura obtidos pela ferramenta GeoDMA, derivados da técnica GLCM – mais usualmente empregada na extração de textura, mostrou-se mais consistente do que os descritores de textura SIFT.

A classificação dos recortes resultou em um intervalo de 83,64% a 95% de acurácia global e 0,74 a 0,92 de coeficiente Kappa. Quanto à área teste – utilizada para produzir os mapas de classificação, obteve-se um intervalo de 59,01% a 84,97% de acurácia global e 0,62 a 0,74 de coeficiente Kappa. Os resultados obtidos com Random Forest mostraram-se satisfatórios, levando em consideração o número de amostras e a quantidade de atributos utilizados. Além disso, os valores de acurácia alcançados equiparam-se àqueles encontrados na literatura em estudos similares.

Sendo assim, a hipótese embasada na viabilidade de descrever as informações de organização espacial, estrutura da folha, particularidades de sombra etc. pelos atributos de textura foi confirmada. A integração de atributos de textura aos atributos espectrais não foi de um ganho substancial na acurácia da classificação, mas sua importância foi comprovada para a discriminação das espécies de VAE.

REFERÊNCIAS

ACHANTA, R.; SHAJI, A.; SMITH, K.; LUCCHI, A.; FUA, P.; SÜSSTRUNK, S. SLIC Superpixels Compared to State-of-the-Art Superpixel Methods. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 34, n. 11, p. 2274–2281, 2012.

ADE, C.; KHANNA, S.; LAY, M.; USTIN, S. L.; HESTIR, E. L. Genus-Level Mapping of Invasive Floating Aquatic Vegetation Using Sentinel-2 Satellite Remote Sensing. **Remote Sensing**, v. 14, n. 13, 2022.

AGROWING, 2023. Disponível em: <<https://agrowing.com/products/alpha-6x00-dual/>>.

ALVAREZ-VANHARD, E.; CORPETTI, T.; HOUET, T. UAV & satellite synergies for optical remote sensing applications: A literature review. **Science of Remote Sensing**, v. 3, 2021.

ARIF, F.; AKBAR, M. Resampling Air Borne Sensed Data Using Bilinear Interpolation Algorithm. In: International Conference on Mechatronics, 2005, Taipei. **Proceedings [...]**. Taipei: IEEE, 2005.

BELGIU, M.; DRAGUT, L. Random forest in remote sensing: A review of applications and future directions. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 14, p. 24–31, 2016.

BENJAMIN, A. R.; ABD-ELRAHMAN, A.; GETTYS, L. A.; HOCHMAIR, H. H.; THAYER, K. Monitoring the efficacy of crested floatingheart (*Nymphoides cristata*) management with object-based image analysis of uas imagery. **Remote Sensing**, v. 13, n. 4, 2021.

BERRAR, D. Cross-Validation. In: **Encyclopedia of Bioinformatics and Computational Biology**, v. 1, p. 542–545, 2018.

BEUCHER, S.; LANTUEJOUL, C. Use of watersheds in contour detection. In: International Workshop on Image Processing: Real-Time Edge and Motion Detection/Estimation, 1979, Rennes. **Proceedings [...]** Rennes: 1979.

BERVEGLIERI, A.; TOMMASELLI, A. M. G. Uso do detector de pontos de interesse SIFT para localização de alvos artificiais de controle. In: Simpósio Brasileiro de Geomática – SBG, 4.; Jornadas Lusófonas - Ciências e Tecnologias de Informação Geográfica – CTIG, 2., 2017, Presidente Prudente. **Anais [...]**. Presidente Prudente: 2017, p. 341–346.

BINS, L. S.; FONSECA, L. M. G.; ERTHAL, G J; MITSUO, F. Satellite Imagery Segmentation: a region growing approach. In: Simpósio Brasileiro de Sensoriamento Remoto, 8., 1996, São José dos Campos. **Anais [...]**. São José dos Campos: INPE, 1996, p. 677–680.

BLANCO, S. R.; HERAS, D. B.; ARGÜELLO, F. Texture extraction techniques for the classification of vegetation species in hyperspectral imagery: Bag of words approach based on superpixels. **Remote Sensing**, v. 12, n. 16, 2020.

BLASCHKE, T. Object-based image analysis for remote sensing. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 65, n. 1, p. 2–16, 2010.

BLASCHKE, T.; HAY, G. J.; KELLY, M.; LANG, S.; HOFMANN, P.; ADDINK, E.; FEITOSA, R. Q.; VAN DER MEER, F.; VAN DER WERFF, H.; VAN COILLIE, F.; TIEDE, D. Geographic Object-based Image Analysis – Towards a new paradigm. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 87, p. 180–191, 2014.

BLASCHKE, T.; LANG, S.; LORUP, E.; STROBL, J.; ZEIL, P. Object-Oriented Image Processing in an Integrated GIS/Remote Sensing Environment and Perspectives for Environmental Applications. **Environmental Information for Planning, Politics and the Public**, v. 2, p. 555–570, 2000.

BOLCH, E. A.; HESTIR, E. L.; KHANNA, S. Performance and Feasibility of Drone-Mounted Imaging Spectroscopy for Invasive Aquatic Vegetation Detection. **Remote Sensing**, v. 13, n. 4, 2021.

BREIMAN, L. Random Forests. **Machine Learning**, v. 45, n. 1, p. 5–32, 2001.

CHABOT, D.; DILLON, C.; SHEMROCK, A.; WEISSFLOG, N.; SAGER, E. P. S. An object-based image analysis workflow for monitoring shallow-water aquatic vegetation in multispectral drone imagery. **ISPRS International Journal of Geo-Information**, v. 7, n. 8, 2018.

CHANDRASHEKAR, G.; SAHIN, F. A survey on feature selection methods. **Computers & Electrical Engineering**, v. 40, n. 1, p. 16–28, 2014.

COHEN, J. A. Coefficient of agreement for nominal scales. **Educational and Psychological Measurement**, v. 20, n. 1, p. 37–46, 1960.

CONGALTON, R. G. Accuracy assessment and validation of remotely sensed and other spatial information. **International Journal of Wildland Fire**, v. 10, n. 4, p. 321–328, 2001.

COSTA, H.; FOODY, G. M.; BOYD, D. S. Supervised methods of image segmentation accuracy assessment in land cover mapping. **Remote Sensing of Environment**, v. 205, p. 338–351, 2018.

DIBIESO, E. P. **Planejamento ambiental e gestão dos recursos hídricos: estudo aplicado à bacia hidrográfica do Manancial do Alto Curso do Rio Santo Anastácio - São Paulo/Brasil**. 2013. Tese (Doutorado em Geografia) – Faculdade de Ciências e Tecnologia, Universidade Estadual Paulista, Presidente Prudente, 2013.

DPI-INPE, 2023. Disponível em: <http://wiki.dpi.inpe.br/doku.php?id=geodma_2:features>.

EMLID BRASIL, 2023. Disponível em: <<https://loja.emlid.com.br/product/reachm-plus/>>.

ESTEVEVES, F. A. **Fundamentos de Limnologia**. 2 ed. Rio de Janeiro: Interciência, 1998.

GAO, Y.; KERLE, N.; MAS, J. F., NAVARRETE, A.; NIEMEYER, I. Optimized Image Segmentation and its Effect on Classification Accuracy. In: International Symposium Spatial Data Quality, 5., 2007, Enschede. **Proceedings** [...]. Enschede: ISPRS Archives, 2007.

GDAL/OGR contributors, 2023. GDAL/OGR Geospatial Data Abstraction Software Library/Open Source Geospatial Foundation. Disponível em: <<https://gdal.org>>.

GEISSER, S. **The Predictive Sample Reuse Method with Applications Source: Journal of the American Statistical Association**, v. 70, n. 350, p. 320–328, 1975.

GENG, R.; JIN, S.; FU, B.; WANG, Bin. Object-Based Wetland Classification Using Multi-Feature Combination of Ultra-High Spatial Resolution Multispectral Images. **Canadian Journal of Remote Sensing**, v. 46, n. 6, p. 784–802, 2020.

GONZÁLES, G. L. G. **Aplicação da Técnica SIFT para Determinação de Campos de Deformações de Materiais**. 2010. Dissertação (Mestrado em Engenharia Mecânica) – Pontifícia Universidade Católica, Rio de Janeiro, 2010.

GOVENDER, M.; CHETTY, K.; BULCOCK, H. A review of hyperspectral remote sensing and its application in vegetation and water resource studies. **Water SA**, v. 33, n. 2, p. 145–151, 2007.

HALL, M. A. **Correlation-Based Feature Selection for Machine Learning**. Hamilton, New Zealand: The University of Waikato, 1999.

HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. Textural Features for Image Classification. **IEEE Transactions on Systems, Man, and Cybernetics**, v. SMC-3, n. 6, p. 610–621, 1973.

HATSUMURA, P. H. **Subsídios para elaboração de projeto de pagamento por serviços ambientais na bacia hidrográfica do Manancial do Alto Curso do Rio Santo Anastácio - UGRHI Pontal do Paranapanema - Estado de São Paulo - Brasil**. 2018. Projeto Técnico (Mestrado Profissional em Gestão e Regulação de Recursos Hídricos) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2018.

HAY, G. J.; Niemann, K. O.; MCLEAN, G. F. An Object-Specific Image-Texture Analysis of H-Resolution Forest Imagery. **Remote Sensing of Environment**, v. 55, n. 2, p. 108–122, 1996.

HOSSAIN, M. D.; CHEN, D. Segmentation for Object-Based Image Analysis (OBIA): A review of algorithms and challenges from remote sensing perspective. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 150, p. 115–134, 2019.

HUSSON, E.; ECKE, F.; REESE, H. Comparison of manual mapping and automated object-based image analysis of non-submerged aquatic vegetation from very-high-resolution UAS images. **Remote Sensing**, v. 8, n. 9, 2016.

INGLADA, J.; CHRISTOPHE, E. The orfeo toolbox remote sensing image processing software. In: International Geoscience and Remote Sensing Symposium (IGARSS), 2009. **Proceedings** [...]. Cape Town: IEEE, 2009.

IRONS, J. R.; PETERSEN, G. W. Texture Transforms of Remote Sensing Data. **Remote Sensing of Environment**, v. 11, p. 359–370, 1981.

JAKUBAUSKAS, M.; KINDSCHER, K.; FRASER, A.; DEBINSKI, D.; PRICE, K. P. Close-range remote sensing of aquatic macrophyte vegetation cover. **International Journal of Remote Sensing**, v. 21, n. 18, p. 3533–3538, 2000.

JANIESCH, C.; ZSCHECH, P.; HEINRICH, K. Machine learning and deep learning. **Electronic Markets**, v. 31, p. 685–695, 2021.

JIANG, W.; LIU, L.; XIAO, H.; ZHU, S.; LI, W.; LIU, Y. Composition and distribution of vegetation in the water level fluctuating zone of the Lantsang cascade reservoir system using UAV multispectral imagery. **PLOS ONE**, v. 16, n. 3, 2021.

JORDAN, C. F. Derivation of leaf-area index from quality of light on the forest floor. **Ecology**, v. 50, n. 4, p. 663–666, 1969.

KEBAPCI, H.; YANIKOGLU, B.; UNAL, G. Plant Image Retrieval Using Color, Shape and Texture Features. **The Computer Journal**, v. 54, n. 9, p. 1475–1490, 2011.

KOHAVI, R. A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection. In: International Joint Conference on Artificial Intelligence, 14., 1995, Montreal. **Proceedings** [...]. Montreal: AIJ, 1995. p. 1137–1143.

KORNILOV, A. S.; SAFONOV, I. V. **An overview of watershed algorithm implementations in open source libraries**. **Journal of Imaging**, v. 4, n. 10, 2018.

KORTING, T. S.; FONSECA, L. M. G.; ESCADA, M. I. S.; SILVA, F. C. GeoDMA - A novel system for spatial data mining. In: International Conference on Data Mining Workshops, 8., 2008, Pisa. **Proceedings** [...]. Pisa: IEEE, 2008.

KUMAR, A.; SODHI, S. S. Comparative Analysis of Gaussian Filter, Median Filter and Denoise Autoencoder. In: International Conference on Computing for Sustainable Global Development, 7., 2020, New Delhi. **Proceedings** [...]. New Delhi: IEEE, 2020.

LI, D.; ZHANG, G.; WU, Z.; YI, L. An Edge Embedded Marker-Based Watershed Algorithm for High Spatial Resolution Remote Sensing Image Segmentation. **IEEE Transactions on Image Processing**, v. 19, n. 10, p. 2781–2787, 2010.

LOWE, D. G. Object Recognition from Local Scale-Invariant Features. In: International Conference on Computer Vision, 7., 1999, Kerkyra. **Proceedings** [...]. Kerkyra: IEEE, 1999.

LOWE, D. G. Distinctive image features from scale-invariant keypoints. **International Journal of Computer Vision**, v. 60, p. 91–110, 2004.

LUO, J.; LI, X.; MA, R.; LI, F.; DUAN, H.; HU, W.; QIN, B.; HUANG, W. Applying remote sensing techniques to monitoring seasonal and interannual changes of aquatic vegetation in Taihu Lake, China. **Ecological Indicators**, v. 60, p. 503–513, 2016.

MA, L.; LI, M.; MA, X.; CHENG, L.; DU, P.; LIU, Y. A review of supervised object-based land-cover image classification. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 130, p. 277–293, 2017.

MAXWELL, A. E.; WARNER, T. A.; FANG, F. Implementation of machine-learning classification in remote sensing: An applied review. **International Journal of Remote Sensing**, v. 39, n. 9, p. 2784–2817, 2018.

MEYER, F.; BEUCHER, S. Morphological Segmentation. **Journal of Visual Communication and Image Representation**, v. 1, n. 1, p. 21–46, 1990.

MYNENI, R. B.; HALL, F. G.; SELLERS, P. J.; MARSHAK, A. L. The Interpretation of Spectral Vegetation Indexes. **IEEE Transactions on Geoscience and Remote Sensing**, v. 33, n. 2, p. 481–486, 1995.

NICHOLS, S. A. The interaction between biology and the management of aquatic macrophytes. **Aquatic Botany**, v. 41, p. 225–252, 1991.

OPENCV contributors, 2023. OpenCV Open Source Computer Vision Library. Disponível em: <<https://opencv.org>>.

OSHIRO, T. M. **Uma abordagem para a construção de uma única árvore a partir de uma Random Forest para classificação de bases de expressão gênica**. 2013. Dissertação (Mestrado em Bioinformática) – Interunidades em Bioinformática, Universidade de São Paulo, São Paulo, 2013.

PAL, M. Random forest classifier for remote sensing classification. **International Journal of Remote Sensing**, v. 26, n. 1, p. 217–222, 2005.

PANDAS contributors, 2023. Python Data Analysis Library. Disponível em: <<https://pandas.pydata.org>>.

PANDE-CHHETRI, R.; ABD-ELRAHMAN, A.; LIU, T.; MORTON, J.; WILHELM, V. L. Object-based classification of wetland vegetation using very high-resolution unmanned air system imagery. **European Journal of Remote Sensing**, v. 50, n. 1, p. 564–576, 2017.

PIASER, E.; VILLA, P. Evaluating capabilities of machine learning algorithms for aquatic vegetation classification in temperate wetlands using multi-temporal Sentinel-2 data. **International Journal of Applied Earth Observation and Geoinformation**, v. 117, 2023.

PIRES, R. D. L.; GONÇALVES, D. N.; ORUÊ, J. P. M.; KANASHIRO, W. E. S.; RODRIGUES JR., J. F.; MACHADO, B. B.; GONÇALVES, W. N. Local descriptors for soybean disease recognition. **Computers and Electronics in Agriculture**, v. 125, p. 48–55, 2016.

POMPÊO, M. **Monitoramento e manejo de macrófitas aquáticas em reservatórios tropicais brasileiros**. 1 ed. São Paulo: Instituto de Biociências da USP, 2017.

- PROCTOR, C.; HE, Y.; ROBINSON, V. Texture augmented detection of macrophyte species using decision trees. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 80, p. 10–20, jun. 2013.
- QING, S.; A, R.; SHUN, B.; ZHAO, W.; BAO, Y.; HAO, Y. Distinguishing and mapping of aquatic vegetations and yellow algae bloom with Landsat satellite data in a complex shallow Lake, China during 1986–2018. **Ecological Indicators**, v. 112, 2020.
- RANÇON, F.; BOMBRUN, L.; KERESZTES, B.; Germain, C. Comparison of SIFT Encoded and Deep Learning Features for the Classification and Detection of Esca Disease in Bordeaux Vineyards. **Remote Sensing**, v. 11, n. 1, 2019.
- REES, W.G. **Physical Principles of Remote Sensing**, 3 ed. Cambridge: Cambridge University Press, 2012.
- RICHARDS, John A. **Remote Sensing Digital Image Analysis: An Introduction**, 5 ed. Heidelberg: Springer Berlin, 2013.
- ROUSE, J. W.; HAAS, R.; SCHELL, J.; DEERING, D. Monitoring vegetation systems in the great plains with erts. In: Earth Resources Technology Satellite-1 Symposium, 3., 1974, Greenbelt. **Proceedings** [...]. Greenbelt: NASA Special Publication, 1974. p. 3010–3017.
- SCHIEWE, J. Segmentation of high-resolution remotely sensed data – concepts, applications and problems. In: Symposium on Geospatial Theory, Processing and Applications, 2002, Ottawa. **Proceedings** [...]. Ottawa: ISPRS Archives, 2002.
- SHEYKHMOUSA, M.; MAHDIANPARI, M.; GHANBARI, H.; MOHAMMADIMANESH, F.; GHAMISI, P.; HOMAYOUNI, S. Support Vector Machine Versus Random Forest for Remote Sensing Image Classification: A Meta-Analysis and Systematic Review. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 13, p. 6308–6325, 2020.
- SCHOWENGERDT, R. A. **Remote Sensing: Models and Methods for Image Processing**, 3 ed. Amsterdam: Elsevier Science & Technology Books, 2006.
- SILVA, T. S. F.; COSTA, M. P. F.; MELACK, J. M.; NOVO, E. M. L. M. Remote sensing of aquatic vegetation: Theory and applications. **Environmental Monitoring and Assessment**, v. 140, p. 131–145, 2008.
- STORY, M.; CONGALTON, R. G. Accuracy assessment: A user's perspective. **Photogrammetric Engineering and Remote Sensing**, v. 52, n. 3, p. 397–399, 1986.
- TELLES JUNIOR, M. A. B. G. **Super-resolução de Imagens de Sensoriamento Remoto**. 2008. Tese (Doutorado em Geologia) – Instituto de Geociências, Universidade de Brasília, Brasília, 2008.
- THOMAZ, S. M. Fatores ecológicos associados à colonização e ao desenvolvimento de macrófitas aquáticas e desafios de manejo. **Planta Daninha**, v. 20, p. 21–33, 2002.

TOMMASELLI, A. M. G.; BERVEGLIERI, A.; IMAI, N. N.; SANTOS, G.H.; MORIYA, E. A. S.; WATANABE, F. S. Y.; SALVADOR NETO, L. Geometric performance of a camera with single sensor and multiple heads. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. XLIII-B1-2020, 2020.

VAN DER WALT, S. et al. Scikit-image: Image processing in python. **PeerJ**, v. 2014, n. 1, 2014.

VAN RIJSBERGEN, C. J. **Information Retrieval**. London: Butterworth-Heinemann, 1979.

VILLA, P.; BRESCIANI, M.; BOLPAGNI, R.; PINARDI, M.; GIARDINO, C. A rule-based approach for mapping macrophyte communities using multi-temporal aquatic vegetation indices. **Remote Sensing of Environment**, v. 171, p. 218–233, 2015.

VISSER, F.; BUIS, K.; VERSCHOREN, V.; SCHOELYNCK, J. Mapping of submerged aquatic vegetation in rivers from very high-resolution image data, using object-based image analysis combined with expert knowledge. **Hydrobiologia**, v. 812, n. 1, p. 157–175, 2018.

WANG, M.; ZHENG, S.; LI, X.; QIN, X. A new image denoising method based on Gaussian filter. In: International Conference on Information Science, Electronics and Electrical Engineering, 2014, Sapporo. **Proceedings [...]**. Sapporo: IEEE, 2014.

WILF, P.; ZHANG, S.; CHIKKERUR, S.; LITTLE, S. A.; WING, S. L.; SERRE, T. Computer vision cracks the leaf code. **Proceedings of the National Academy of Sciences**, v. 113, n. 12, p. 3305–3310, 2016.

XFLY TECNOLOGIA, 2023. Disponível em:
<<https://www.xflytecnologia.com.br/produto/x800-geo>>.

ZHANG, X.; FENG, X.; XIAO, P.; HE, G.; ZHU, L. Segmentation quality evaluation using region-based precision and recall measures for remote sensing images. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 102, p. 73–84, 2015.

ZHOU, R.; YANG, C.; LI, E.; CAI, X.; YANG, J.; XIA, Y. Object-based wetland vegetation classification using multi-feature selection of unoccupied aerial vehicle rgb imagery. **Remote Sensing**, v. 13, n. 23, 2021.