



**REBECCA ARAÚJO GARCIA**

**AVALIAÇÃO DO EFEITO DA ALTITUDE DE VOO E  
ILUMINAÇÃO NA CLASSIFICAÇÃO DO USO DO SOLO  
USANDO ALGORITMOS DE MACHINE LEARNING E  
IMAGENS MULTIESPECTRAIS DE VANT**

**LAVRAS - MG**

**2023**

**REBECCA ARAÚJO GARCIA**

**AVALIAÇÃO DO EFEITO DA ALTITUDE DE VOO E ILUMINAÇÃO NA  
CLASSIFICAÇÃO DO USO DO SOLO USANDO ALGORITMOS DE MACHINE  
LEARNING E IMAGENS MULTIESPECTRAIS DE VANT**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-graduação em Engenharia Florestal, área de concentração em Manejo Florestal, para a obtenção do título de Mestre.

Prof. Dr. Luís Marcelo Tavares de Carvalho  
Orientador

**LAVRAS - MG  
2023**

**Ficha catalográfica elaborada pelo Sistema de Geração de Ficha Catalográfica da Biblioteca  
Universitária da UFLA, com dados informados pelo(a) próprio(a) autor(a).**

Garcia, Rebecca Araújo.

Avaliação do efeito da altitude de voo e iluminação na  
classificação do uso do solo usando algoritmos de machine learning  
e imagens multiespectrais de VANT / Rebecca Araújo Garcia. -  
2023.

72 p.

Orientador(a): Luís Marcelo Tavares de Carvalho.

Dissertação (mestrado acadêmico) - Universidade Federal de  
Lavras, 2023.

Bibliografia.

1. Sensoriamento Remoto. 2. Veículo Aéreo Não Tripulado -  
VANT. 3. Machine Learning. I. Carvalho, Luís Marcelo Tavares de.  
II. Título.

**REBECCA ARAÚJO GARCIA**

**AVALIAÇÃO DO EFEITO DA ALTITUDE DE VOO E ILUMINAÇÃO NA  
CLASSIFICAÇÃO DO USO DO SOLO USANDO ALGORITMOS DE MACHINE  
LEARNING E IMAGENS MULTIESPECTRAIS DE VANT**

**AVALUATION OF THE EFFECT OF FLIGHT ALTITUDE AND LIGHTING ON LAND  
USE CLASSIFICATION USING MACHINE LEARNING ALGORITHMS AND  
MULTISPECTRAL UAV IMAGES**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-graduação em Engenharia Florestal, área de concentração em Manejo Florestal, para a obtenção do título de Mestre.

APROVADA em 28 de julho de 2023  
Dr. Luís Marcelo Tavares de Carvalho UFLA  
Dr. Samuel José Silva Soares da Rocha UFLA  
Dra. Marcela de Castro Nunes Santos Terra UFSJ

Prof. Dr. Luís Marcelo Tavares de Carvalho  
Orientador

**LAVRAS - MG  
2023**

## **AGRADECIMENTOS**

Primeiramente, agradeço à Deus, cujo auxílio foi fundamental para superar os obstáculos, me dando forças para concluir essa dissertação de mestrado

Aos meus pais, Valdeny e Rosley, por todos os sacrifícios, me oferecerem suporte e amor incondicional não apenas durante essa fase, mas em toda a minha vida. Eles sempre acreditaram em mim, e sou imensamente grata por isso.

À minha família pelo carinho e companheirismo, e o incentivo a constante busca pelo conhecimento.

Aos meus amigos que estiveram presentes ao longo dessa caminhada, sempre oferecendo apoio, mesmo nos momentos mais difíceis, com quem compartilhei angústias e alegrias. Quero expressar minha gratidão a Sueliane, Bruno e Talita. E um agradecimento especial ao Fabiano, cuja colaboração foi fundamental nessa etapa tão importante.

Ao professor Luís Marcelo, por todo o apoio e ensinamentos ao longo desses anos.

Por fim, meus sinceros agradecimentos, a todos que participaram direta ou indiretamente para que meu trabalho pudesse ser concluído.

À Universidade Federal de Lavras, em especial ao Programa de Pós-Graduação em Engenharia Florestal por me proporcionarem tantos aprendizados.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG), pelo apoio financeiro.

## RESUMO

Informações sobre o uso e cobertura do solo em áreas urbanas desempenham um papel importante para o planejamento urbano, fornecendo informações essenciais para análises de adequação do solo, avaliações ambientais e projetos de regeneração urbano. Em comparação com o sensoriamento remoto baseado em satélite, o sensoriamento remoto por Veículo Aéreo Não Tripulado (VANT) possui uma resolução espacial e temporal mais alta, o que proporciona um método mais eficaz para a classificação de uso do solo. Neste estudo, avaliou-se a influência da altitude de voo (120 m e 150 m) e iluminação (difusa e direta) na classificação de uso do solo combinando uma abordagem orientada a objetos (GEOBIA) e um algoritmo de aprendizagem de máquina usando imagens multiespectrais de VANT. Primeiramente, as imagens foram segmentadas pelos algoritmos *Multiresolution segmentation* e *Spectral Difference segmentation*. Em seguida, características espectrais, índices, texturais e geométricas foram combinadas para formar os esquemas S1-S8. Finalmente, a classificação da área foi realizada com base nos oito esquemas usando os classificadores de *Random Forest* (RF) e *Support Vector Machine* (SVM). Os resultados mostraram que o classificador de *Random Forest* teve um desempenho melhor do que o *Support Vector Machine* em todos os esquemas. As características geométricas apresentaram um impacto negativo na precisão da classificação do SVM, enquanto os outros três tipos de características têm um impacto positivo. Entretanto, esse comportamento não foi notado no RF, visto que, o classificador de *Random Forest* alcançou uma precisão geral (AO) de 82% ao combinar as características espectrais, texturais e geométricas (S6), para a imagem obtida a 150 m de altitude sob iluminação difusa.

**Palavras chave:** Veículo Aéreo Não Tripulado (VANT). *Random Forest*. *Support Vector Machine*. Análise de imagem orientada a objetos (OBIA).

## ABSTRACT

Information about land use and land cover in urban areas plays an important role in urban planning, providing essential insights for land suitability analysis, environmental assessments, and urban regeneration projects. Compared to satellite-based remote sensing, Unmanned Aerial Vehicle (UAV) remote sensing offers higher spatial and temporal resolution, making it a more effective method for land use classification. In this study, the influence of flight altitude (120 m and 150 m) and illumination (diffuse and direct) on land use classification was evaluated by combining an Object-Based Image Analysis (GEOBIA) approach with a machine learning algorithm using multispectral UAV images. Firstly, the images were segmented using the Multiresolution segmentation and Spectral Difference segmentation algorithms. Then, spectral, index, texture, and geometric features were combined to form schemes S1-S8. Finally, area classification was performed based on the eight schemes using the Random Forest (RF) and Support Vector Machine (SVM) classifiers. The results showed that the Random Forest classifier outperformed the Support Vector Machine in all schemes. Geometric features had a negative impact on the SVM classification accuracy, while the other three types of features had a positive impact. However, this behavior was not observed in RF, as the Random Forest classifier achieved an overall accuracy (AO) of 82% when combining spectral, texture, and geometric features (S6) for the image obtained at 150 m altitude under diffuse illumination.

**Key words:** Unmanned Aerial Vehicle (UAV). Random Forest. Support Vector Machine (SVM). Object-Based Image Analysis (OBIA).

## LISTA DE FIGURAS

Figura 1 - Classificação usando Random Forest. ....	20
Figura 2 - Estrutura de um classificador Support Vector Machine. À direita é ilustrado o hiperplano que maximiza a margem entre duas classes. ....	22
Figura 3 - Comparação dos efeitos da iluminação solar direta, iluminação atmosférica difusa, dispersão refletida dos objetos e radiação espalhada pela atmosfera em um dia ensolarado (A) e um dia com cobertura de nuvens (B). ....	23
Figura 4 - Equipamento de medição VANT DJI Matrice 100 .....	29
Figura 5 - Sensor RedEdge-M da MicaSense.....	30
Figura 6 - Fluxograma de trabalho. ....	32
Figura 7 – Resultados da segmentação de ortomosaico multiespectral por meio do algoritmo <i>Multiresolution Segmentation</i> (MRS) e <i>Spectral Difference Segmentation</i> utilizado o software eCognition Developer 9.....	33
Figura 8 - Pontos aleatórios para verificação da acurácia. ....	39
Figura 9 - A acurácia geral (OA) de classificação, índice Kappa e F1-score de diferentes classificadores e esquemas diferentes para a classificação da imagem adquirida a 120 m de altitude e iluminação direta.....	41
Figura 10 - A acurácia geral de classificação, índice Kappa e F1-score de diferentes classificadores e esquemas diferentes para a classificação da imagem adquirida a 120 m de altitude e iluminação difusa. ....	42
Figura 11 - A acurácia geral de classificação, índice Kappa e F1-score de diferentes classificadores e esquemas diferentes para a classificação da imagem adquirida a 150 m de altitude e iluminação direta. ....	43
Figura 12 - A acurácia geral de classificação, índice Kappa e F1-score de diferentes classificadores e esquemas diferentes para a classificação da imagem adquirida a 150 m de altitude e iluminação difusa. ....	44
Figura 13 - Resultados de importância das variáveis de acordo com cada um dos esquemas (S1 a S8) para imagem adquirida a 120 m de altitude e iluminação direta. ....	46
Figura 14 - Resultados de importância das variáveis de acordo com cada um dos esquemas (S1 a S8) para imagem adquirida a 120 m de altitude e iluminação difusa. ....	47



Figura 15 - Resultados de importância das variáveis de acordo com cada um dos esquemas (S1 a S8) para imagem adquirida a 150 m de altitude e iluminação direta. ....	48
Figura 16 - Resultados de importância das variáveis de acordo com cada um dos esquemas (S1 a S8) para imagem adquirida a 150 m de altitude e iluminação difusa.....	49
Figura 17 - Resultado da classificação para os algoritmos RF (A) e SVM (B) baseado no melhor esquema para a imagem adquirida a 120 m de altitude e iluminação direta. ....	50
Figura 18 - Resultado da classificação para os algoritmos RF (A) e SVM (B) baseado no melhor esquema para a imagem adquirida a 120 m de altitude e iluminação difusa.....	52
Figura 19 - Resultado da classificação para os algoritmos RF (A) e SVM (B) de classificação baseado no melhor esquema para a imagem adquirida a 150 m de altitude e iluminação direta. .	53
Figura 20 - Resultado da classificação para os algoritmos RF (A) e SVM (B) de classificação baseado no melhor esquema para a imagem adquirida a 150 m de altitude e iluminação difusa. .	55

## SUMÁRIO

1. INTRODUÇÃO.....	10
2. REFERENCIAL TEÓRICO.....	14
2.1. Sensoriamento Remoto com uso de Veículos aéreos não tripulados (VANTs).....	14
2.2. Análise de Imagem Baseada em Objetos Geográficos (GEOBIA).....	16
2.3. Classificação de imagem.....	19
2.3.1. Random Forest.....	19
2.3.2. Support Vector Machine.....	21
2.4. Iluminação.....	23
2.5. Altitude de voo.....	25
2.6. Medidas de Textura.....	25
2.7. Índices de Vegetação.....	27
3. MATERIAL E MÉTODOS.....	29
3.1. Aquisição e pré-processamento de imagens de VANT.....	29
3.2. Método de pesquisa.....	30
3.2.1 Segmentação de imagens.....	31
3.2.2 Extração das variáveis preditoras.....	34
3.2.3. Construção de conjuntos para esquemas diferentes.....	36
3.2.4. Amostras de treinamento e verificação da precisão.....	36
3.2.4 Métodos de Classificação.....	37
3.2.5 Avaliação da precisão do ajuste dos modelos.....	37
3.2.6 Avaliação da precisão do mapa.....	38
4. RESULTADOS E DISCUSSÃO.....	41
4.1. Acurácia dos modelos.....	41
4.2. Importância das características.....	45
4.3. Classificação e avaliação de precisão.....	49
CONCLUSÃO.....	58
REFERÊNCIA BIBLIOGRÁFICA.....	59

## 1. INTRODUÇÃO

O mapeamento da cobertura do solo desempenha um papel crucial na compreensão e gestão das mudanças ambientais, considerando a influência significativa das atividades humanas nesse contexto. Esse mapeamento em escalas globais, regionais e locais, é fundamental para um monitoramento mais eficaz de um mundo em constante transformação (YAN; SHAKER; EL-AHMAWAY, 2015). Além disso, nas áreas urbanas, as mudanças no Uso e Cobertura do Solo (LULC, do inglês: *Land Use and Land Cover*) afetam diretamente o ambiente, influenciando o balanço energético e hidrológico (CHEN *et al.*, 2015), bem como processos vitais como de evaporação, transpiração e fluxo de calor na superfície do solo. Esses dados referentes à cobertura da terra são essenciais em diversas áreas, incluindo pesquisas ambientais, estudos ecológicos, análises das mudanças climáticas e o monitoramento e gerenciamento de recursos naturais (ADUGNA; XU; JUNLONG, 2022).

Uma das formas mais eficazes de registrar e transmitir essas informações, é através de mapas de cobertura do solo, que são gerados seguindo sistemas de classificação específicos, levando em consideração as características ópticas e físicas da superfície terrestre, sendo cruciais para avaliar o estado atual de uma determinada região. Nas áreas urbanas, esses mapas desempenham um papel fundamental como base científica para o planejamento urbano, fornecendo informações essenciais para análises de adequação do solo, avaliações ambientais e projetos de regeneração urbana (PARK *et al.*, 2022).

Dada à sua capacidade de capturar informações em diferentes momentos e a um custo razoável, o uso de dados obtidos por sensoriamento remoto tornou-se indispensável na produção desses mapas (NGUYEN; DOAN; RADELOFF, 2018). No entanto, o mapeamento das mudanças ao longo do tempo e no espaço, tanto em áreas urbanas como rurais, continua sendo um desafio, pois as ferramentas e instrumentos tecnológicos disponíveis até o momento não têm sido adequados para atender às necessidades diárias dos planejadores e tomadores de decisão, levando em consideração as dimensões espaciais e temporais (CHATURVEDI; VRIES, 2021).

A inconsistência na cobertura da terra pode surgir devido às discrepâncias nos ciclos de atualização de satélites e imagens aéreas digitais utilizados no processo de produção dos mapas de cobertura da terra. Portanto, é essencial estabelecer mapas de cobertura da terra com alta produtividade e precisão, especialmente para áreas de médio e pequeno porte (VAN IERSEL *et al.*, 2018; YOO *et al.*, 2020; PARK *et al.*, 2022).

Nos últimos anos, os Veículos Aéreos Não Tripulados (VANTs) se tornaram uma ferramenta popular para coleta de dados por sensoriamento remoto, e tem sido extensivamente investigada (TORRESAN *et al.*, 2017; KALANTAR *et al.*, 2019; YAO; QIN; CHEN, 2019). Consequentemente, uma ampla gama de aplicações de VANTs emergiu em diversos campos científicos, desde mapeamento de cobertura do solo e monitoramento ambiental até levantamentos precisos de engenharia civil (AL-NAJJAR *et al.*, 2019; ADUGNA; XU; JUNLONG, 2022; GUO *et al.*, 2022; ELAMIN; EL-RABBANNY, 2022).

Os veículos aéreos não tripulados (VANTs) são considerados eficazes em termos de custos, devido à flexibilidade temporal superior e à aquisição de imagens de maior resolução em comparação com outras plataformas de sensoriamento remoto, como satélites e aeronaves tripuladas (BALUJA *et al.*, 2012; MATESE *et al.*, 2015; PÁDUA *et al.*, 2017). Além disso, o desenvolvimento recente na tecnologia de sensores aumentou as capacidades de carga útil dos VANTs para incluir vários sensores, como câmeras de alta resolução espacial, câmeras multiespectrais e detecção e alcance de luz (LiDAR) (ELAMIN; EL-RABBANNY, 2022).

Outra vantagem, é sua capacidade de aquisição de imagens em diversas situações de exposição à radiação solar, abrangendo diferentes proporções de luz difusa em relação à luz solar direta incidente, bem como diversos ângulos de incidência da luz solar direta (HASHIMOTO *et al.*, 2019). Uma vez que, as diferentes condições de radiação solar causam uma diferença na refletância observada para o mesmo objeto (BORGOGNO-MONDINO; LESSIO; GOMARASCA, 2016).

No entanto, existem desafios na utilização do mapeamento com VANTs, dado o grande número de combinações potenciais entre sistema, sensor e configuração de voo, como altitude de voo, as limitações ao pesquisar grandes áreas usando plataformas VANT permanecem desconhecidas (FLORES-DE-SANTIAGO *et al.*, 2020). Além disso, devido à baixa altitude de voo (inferior a 200 metros), a área coberta por cada imagem é limitada. Para abranger a extensão da área de pesquisa desejada, as campanhas de voo com VANTs normalmente capturam centenas de imagens durante o trajeto. O processamento desses dados exige um fluxo de trabalho complexo, incluindo correções geométricas e radiométricas, além de ortorretificação e mosaicação posterior, com o objetivo de gerar ortofotos (WANG *et al.*, 2019).

Embora muitos estudos listem uma gama de aplicações às quais as imagens de VANT foram aplicadas, a maioria desses estudos de sensoriamento remoto óptico, foram adquiridos sob

condições de sol e alta irradiância (ARROYO-MORA *et al.*, 2021). Como a iluminação direta e consistente tem sido considerada essencial para várias aplicações de sensoriamento remoto óptico, o principal fator limitante para a aquisição de dados VANT permanece sendo as condições climáticas variáveis (BANERJEE *et al.*, 2020). No entanto, em situações onde as condições de irradiância baixa e variável são frequentes, há desafios adicionais para obter imagens VANT de alta qualidade, incluindo sensibilidade da câmera e sombras de nuvens em imagens (HONKAVAARA *et al.*, 2012).

Os métodos de classificação convencionais são principalmente fundamentados na análise de pixels, utilizando apenas características espectrais (KEYPORT *et al.*, 2018). No entanto, a classificação de imagens de alta resolução espacial por meio da abordagem pixel a pixel pode apresentar um aspecto granuloso (“*salt and pepper*”), no qual a mesma categoria pode ser classificada em diferentes categorias devido à significativa variação espectral (CAMPOS *et al.* 2013). Por outro lado, os métodos orientados a objetos, que se baseiam em segmentos de objetos homogêneos em vez de pixels individuais para a classificação, têm a capacidade de explorar completamente recursos adicionais, como características geométricas, texturais, entre outros (MYINT *et al.*, 2011).

Entretanto, essa abordagem pode acarretar um aumento considerável na redundância de dados, já que as dimensões das características empregadas nos métodos de classificação orientados a objetos tendem a crescer substancialmente (GUO *et al.*, 2022). A eficácia dos algoritmos convencionais é limitada quando tratam de dados com alta dimensionalidade, o que destaca a necessidade de desenvolver abordagens inovadoras. Nesse sentido, os algoritmos de aprendizagem de máquina estão entre os classificadores mais avançados e robustos que ganharam grande aceitação (ADUGNA; XU; JUNLONG, 2022).

Dentre esses, destaca-se o *Random Forest* (RF) e *Support Vector Machine* (SVM) como os algoritmos de aprendizado de máquina mais amplamente empregados e eficazes, uma vez que são métodos supervisionados não paramétricos que não fazem suposições sobre a distribuição estatística de conjuntos de dados de entrada, ao contrário dos algoritmos supervisionados tradicionais (WULDER *et al.*, 2018).

Dadas as limitações acima mencionadas, otimizar a altitude de voo e condições de iluminação é de extrema importância. Diante disso, os objetivos deste estudo foram: (1) Determinar quais os melhores parâmetros de altitude de voo e condições de luminosidade para a realização de

classificação do uso e cobertura do solo; (2) Comparar o desempenho dos algoritmos *Random Forest* (RF) e *Support Vector Machine* (SVM), utilizando diferentes esquemas de combinação de variáveis preditoras; (3) determinar a importância de diferentes variáveis preditoras na classificação das imagens e, por fim, (4) indicar a metodologia mais adequada para a classificação de imagem na área em estudo.

## 2. REFERENCIAL TEÓRICO

### 2.1. Sensoriamento Remoto com uso de Veículos aéreos não tripulados (VANTs)

O Sensoriamento Remoto pode ser definido como a ciência de obtenção de dados sobre a superfície da Terra sem que haja contato físico direto com a área ou fenômeno. É realizada a obtenção, registro e análise das interações da radiação eletromagnética (REM) e as diversas coberturas da superfície terrestre, posteriormente, convertidas em informações através de técnicas de processamento digital (NOVO, 1992; CAMPBELL; WYNNE, 2011).

A origem do sensoriamento remoto está ligada ao desenvolvimento de sensores fotográficos (*American Society of Photogrammetry - ASP*, 1975), podendo ser dividida em dois períodos principais, no período inicial era baseado na utilização de fotografias aéreas, e a partir de 1960, caracterizado pelo uso de sistemas sensores (JENSEN, 2009).

A coleta dos dados pode ser em nível orbital, suborbital e terrestre. A nível orbital é realizada por meio de sensores a bordo de satélites artificiais, permitindo a repetitividade das informações e monitoramento de grandes áreas da superfície. No suborbital os sensores são acoplados em aeronaves ou balões, em que a resolução espacial dos dados dependerá da altura do voo. Por sua vez, a nível do solo, a aquisição de dados é realizada por meio de radiômetros e espectroradiômetros, em que o último se caracteriza por operar em faixas espectrais estreitas (MOREIRA, 2001).

Os sensores utilizados em observações terrestres podem ser classificados como ativos ou passivos. Os sensores passivos são projetados para detectar a radiação eletromagnética natural emitida pelo sol, pela atmosfera e pela superfície da Terra, principalmente nos comprimentos de onda das regiões óptica, termal e de micro-ondas do espectro eletromagnético. Esses sensores aproveitam a radiação emitida ou refletida e não requerem uma fonte de energia externa. Por outro lado, os sensores ativos emitem sua própria radiação em direção ao alvo e medem características da energia que retorna ao sensor após ser refletida pelo objeto, como nos casos dos equipamentos de detecção e alcance de luz (LiDAR) e de detecção e alcance de rádio (RADAR) (PÁDUA *et al.*, 2017).

A quantidade de energia eletromagnética captada pelos sensores, ou seja, a reflectância dependerá da energia incidente comparada à capacidade de um objeto absorver e transmitir a radiação eletromagnética, geralmente manifestadas pela variação de luminância sobre as imagens

(SABINS, 2000). Essa interação depende do comprimento de onda da energia e a natureza do material do objeto (ZHU *et al.*, 2018).

Os sensores decompõem a radiação incidente em diferentes comprimentos de ondas, sendo que a intensidade de energia refletida pelo objeto pode ser medida continuamente ao longo do espectro eletromagnético (NOVO, 1992). Isso resulta em um conjunto de dados, conhecidos como assinatura espectral, que consiste na intensidade, forma e localização de cada banda de absorção. Essa assinatura espectral é responsável por descrever e identificar as características distintas do objeto, ou seja, define suas características físicas.

Como os sistemas de sensoriamento remoto detectam diferentes porções da radiação eletromagnética, como gama, raio x, ultravioleta, luz visível, infravermelho, micro-ondas que diferem entre si pelo comprimento de onda, é possível a análise das radiações que não são visíveis ao olho humano (ELACHI; ZYL, 2021). Atualmente, a utilização de geotecnologias e o processamento digital de imagem, tem auxiliado no mapeamento de grandes áreas, visando compreender a dinâmica da superfície da Terra (RODRIGUEZ-GALIANO *et al.*, 2012) além de monitorar as mudanças em seu uso e cobertura.

Dados detectados por satélite podem conter vieses e imprecisões decorrentes da distância e da atmosfera entre a plataforma e o objetivo. Por este motivo, devido à sua modularidade e rápida implantação, os VANTs atualmente fornecem uma solução econômica em escala detalhada. No contexto de análise da cobertura da Terra, VANTs equipados com sensores específicos podem fornecer um meio útil para obter informações em áreas onde o mapeamento de satélite provou ser menos preciso.

Os VANTs, consistem em qualquer aeronave que possa ser remotamente pilotada ou que tenha a capacidade de executar voos autônomos com trajetórias previamente programadas, e tem sido usado em um amplo espectro de aplicações, que vão desde fotografia aérea a fins militares. Esse interesse surge em função da flexibilidade da programação dos voos e possibilidade de voo em baixas altitudes, permitindo coletar dados aéreos de sensoriamento remoto, com altas resoluções temporais e espaciais (por exemplo, pixels de alguns centímetros) (XIANG; TIAN, 2011), possibilitando a análise de características únicas do fenômeno considerado, bem como os custos mais baixos para coberturas de áreas pequenas e médias quando comparados às plataformas tradicionais (MATESE *et al.*, 2015) e facilidade de operação em áreas de difícil acesso e perigosas (DRONOVA *et al.*, 2021).



Além disso, são capazes de adquirir dados georreferenciados de alta resolução espacial e temporal de diferentes sensores explorando diferentes partes do espectro eletromagnético (PÁDUA *et al.*, 2017), o que permite a detecção e monitoramento de mudanças ambientais em diferentes escalas. Esses sensores podem ser operados no tempo desejado permitindo ao usuário otimizar o tempo exato do voo para evitar, por exemplo, cobertura de nuvens.

À medida que essa tecnologia de obtenção de dados fornece benefícios, novos obstáculos são encontrados. Comumente, as câmeras usadas nos VANTs contêm apenas três bandas visíveis (RGB) gerando uma resolução espectral limitada. Assim, pela falta de bandas de infravermelho, geralmente as bandas do visível não são suficientes para identificar e classificar a vegetação (LIU *et al.*, 2020). Além disso, apresenta dificuldade de imageamento de grandes áreas devido a autonomia de voo, dependendo da velocidade do vento pode haver distorções nas imagens obtidas e há uma dependência das condições climáticas.

Ainda, devido à alta resolução há necessidade de vasta memória para o armazenamento de dados, conhecimento técnico necessário para processamento e maior variabilidade espectral intra-classe. Por conta dessas características, pode haver o efeito “salt and pepper” (pixels isolados dentro de áreas homogêneas), em função da aplicação de uma classificação de imagem baseada em pixels, onde apenas a resposta espectral de cada pixel é analisada de maneira individualizada, impedindo a formação de áreas homogêneas. Assim, a utilização do método de classificação baseado em objetos seria mais adequada para evitar esse tipo de problema (LECHNER *et al.*, 2012), pois ele fornece uma solução apropriada para capturar objetos terrestres significativos enquanto reduz a alta variabilidade espectral em imagens de alta resolução espacial (CHEN *et al.*, 2012).

Além disso, é necessário um cuidado especial na obtenção de autorizações e na garantia da segurança das operações, de acordo com as regulamentações locais. Apesar dos desafios, a utilização de VANTs no sensoriamento remoto apresenta grande potencial para a obtenção de informações mais precisas e detalhadas sobre a superfície terrestre em diferentes contextos e, com o avanço contínuo da tecnologia de VANTs e a evolução das técnicas de processamento de dados, é possível esperar uma crescente utilização dessa abordagem no futuro.

## **2.2. Análise de Imagem Baseada em Objetos Geográficos (GEOBIA)**

Em geral, se o tamanho do pixel de uma imagem é igual ou mais grosseiro que o objeto de interesse, uma classificação pixel a pixel é apropriada (BLASCHKE, 2010). A técnica de

classificação pixel a pixel simplesmente se refere a que cada pixel da imagem original será avaliado e classificado em um novo valor. No entanto, com resoluções mais altas, os pixels podem ser muito menores do que o objeto de interesse, aumentando a complexidade geral da imagem, pois objetos individuais são divididos em vários pixels.

A necessidade de resolver o problema em que vários pixels compõem um objeto alvo, além de obter resultados mais precisos nos estudos de uso e cobertura do solo, impulsionou o desenvolvimento de uma nova abordagem para a análise de imagens, que mudou o enfoque do pixel para o objeto. Até recentemente, a técnica era frequentemente denominada, simplesmente como análise de imagem baseada em objetos (BLASCHKE, 2010; LALIBERTE, 2010). No entanto, a palavra ‘geográfica’, tem sido mais usada para dar o enfoque em aplicações de Sensoriamento Remoto e Sistemas de Informação Geográfica (SIG) (HAY; CASTILLA, 2008; WULDER *et al.*, 2008).

A Análise de imagem baseada em objetos geográficos (GEOBIA, do inglês: *Geographic Object-Based Image Analysis*) é uma técnica de processamento de imagens de sensoriamento remoto que se baseia no reconhecimento de padrões, em que é realizada a segmentação da imagem em objetos, que são compostos por conjuntos de pixels com características semelhantes e que sejam adjacentes, e em seguida, classificá-los com base em suas características.

Essa abordagem representa um progresso em relação às classificações convencionais, pois parte do pressuposto que existe um modelo de conhecimento durante o processo de interpretação. Isso torna a técnica mais próxima do modo como o cérebro humano interpreta, reconhecendo padrões e categorias em imagens (FRANCISCO; ALMEIDA, 2012). O sistema utiliza a identificação de características como heterogeneidade espacial (índices de forma, compacidade e suavidade), heterogeneidade espectral (cor) e diferenças em relação aos objetos vizinhos e em escala (tamanho dos objetos) para realizar a classificação.

Essa metodologia tem sido amplamente utilizada na análise de áreas urbanas, rurais e florestais, com o objetivo de identificar e caracterizar objetos de interesse, como edifícios, estradas, culturas agrícolas e florestas (BLASCHKE *et al.*, 2014). Tem como objetivo principal analisar imagens de alta resolução espacial usando características espectrais, espaciais, texturais e topológicas (LANG, 2008). Para aplicar a GEOBIA em imagens de VANT, baseia-se em dois procedimentos metodológicos: (1) segmentação da imagem em objetos, (2) extração de atributos dos objetos e classificação de regiões por meio de regras de decisão (LANG, 2008).

A segmentação de imagem é uma etapa fundamental na análise de imagens de VANT para a GEOBIA (CHENG *et al.*, 2019). Segundo Wulder *et al.* (2008), consiste na divisão da imagem em segmentos (objetos) não sobrepostos, com base na maior similaridade entre os pixels dentro de um limite definido em relação aos pixels vizinhos. Diversas técnicas de segmentação estão disponíveis, incluindo a segmentação baseada em regiões, bordas e pixel, em que a escolha da técnica mais adequada dependerá das características da imagem e dos objetivos da análise (ZHONG *et al.*, 2021).

Atualmente, existe uma grande variedade de algoritmos de segmentação disponíveis, sendo que, os algoritmos baseados em regiões são os mais adequados para o campo de sensoriamento remoto (WANG *et al.*, 2010). Isso se deve à sua capacidade de combinar pixels em áreas com características espectrais semelhantes, tanto em diferentes escalas quanto em áreas homogêneas (BENZ *et al.*, 2004), refletindo, assim, a maneira como os seres humanos percebem e agrupam o espaço geográfico em objetos homogêneos hierárquicos (GORTE, 1998).

De acordo com Hossain e Chen (2019), o algoritmo de segmentação de abordagem multirresolução (MRS) tem sido amplamente empregado na literatura e tem demonstrado resultados positivos. Esse algoritmo foi originalmente proposto por Baatz e Schäpe (2000) e, conforme mencionado por Francisco e Almeida (2012), ele produz uma camada de imagem contendo objetos formados pela fusão de pixels com base em critérios de homogeneidade.

Segundo Francisco e Ferreira (2012), após a segmentação inicia-se a fase de criação da base de conhecimento orientada a objeto, que consiste em uma rede semântica hierárquica, na qual o intérprete armazena seu conhecimento sobre a área de estudo. É a partir dessa base de conhecimento que os objetos são classificados. Enquanto, o processo de classificação envolve o agrupamento de objetos ou segmentos que possuem características semelhantes, resultando na criação de um mapa que contém informações temáticas da área em questão, revelando a distribuição geográfica das diferentes classes presentes (BLASCHKE; KUX, 2007).

No entanto, é importante destacar que a GEOBIA apresenta desafios, como a seleção adequada de parâmetros e características dos objetos, a complexidade na definição de regras e a necessidade de um conjunto de dados de treinamento representativo e de alta qualidade (LANG *et al.*, 2019). Além disso, a precisão da classificação pode ser afetada pela qualidade da segmentação dos objetos e pela presença de sombreamento e sobreposição de objetos na imagem (BLASCHKE *et al.*, 2014).

### 2.3. Classificação de imagem

A classificação digital de imagens é uma técnica que busca reconhecer padrões homogêneos na imagem e associá-los a uma determinada classe (PONZONI *et al.*, 2012). Tradicionalmente, o processo de classificação de imagens é dividido em métodos supervisionados e não supervisionados. No método não supervisionado, ocorre uma busca automática para identificar grupos de valores semelhantes na imagem. Esses grupos são rotulados manualmente a uma classe de informação pelo usuário quando o processo termina (CHUVIECO, 2016). Já o método supervisionado exige conhecimento prévio do usuário, que deve indicar previamente quais classes de informação devem ser classificadas. Para isso, são coletadas amostras de treinamento, que são utilizadas para gerar os padrões e assim rotular os pixels como pertencentes a uma determinada classe (NOVO, 2011; CHUVIECO, 2016).

Entre os métodos de classificação, os algoritmos paramétricos têm sido criticados por sua capacidade limitada de classificar dados de alta dimensão e multifonte (GHOSH *et al.*, 2014), bem como alta variabilidade espectral dentro da classe (ZHANG *et al.*, 2006), visto que, assumem uma distribuição específica dos dados e estimam os parâmetros dessa distribuição. Por outro lado, os classificadores não paramétricos não fazem suposições específicas sobre a distribuição dos dados, estes aprendem com base nas características dos dados de treinamento e são mais flexíveis em termos de modelagem.

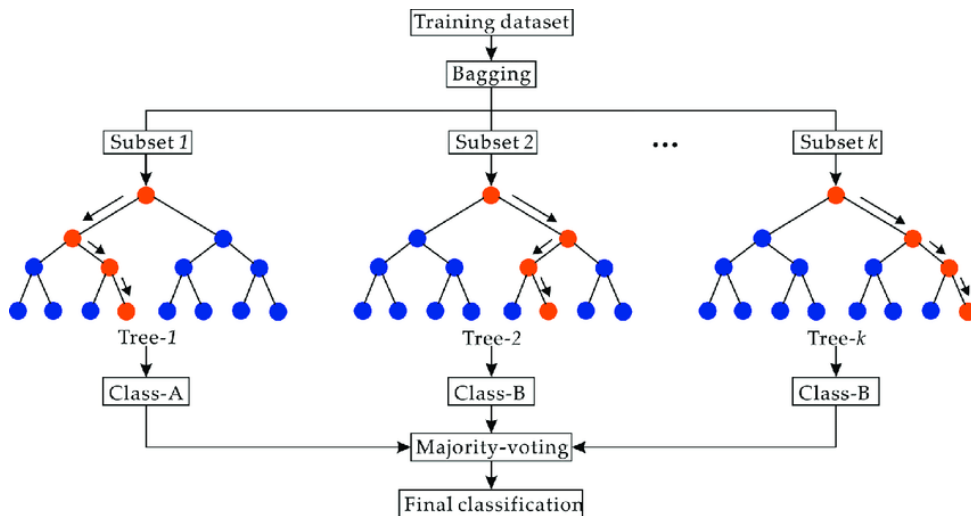
Consequentemente, métodos não paramétricos, como os baseados em aprendizado de máquina, têm recebido atenção crescente nessas aplicações (DENG *et al.*, 2016). Algoritmos como *Random Forest* (RF) e *Support Vector Machine* (SVM) são classificadores de aprendizagem de máquina amplamente usados em sensoriamento remoto para várias aplicações, pois não fazem suposições estatísticas sobre o conjunto de dados, e produzem alta precisão de classificação com menor quantidade de dados de treinamento (NOI; KAPPAS, 2018).

#### 2.3.1. Random Forest

O algoritmo *Random Forest* (RF), proposto por Breiman em 2001, é um algoritmo supervisionado que utiliza *ensemble learning* (*bootstrap aggregation* ou *bagging*) em árvores de decisão. O RF consiste em um grande conjunto de árvores, onde cada árvore é construída a partir de dados de treinamento selecionados aleatoriamente para realizar a classificação (NGUYEN;

DOAN; RADELOFF, 2018). Os resultados de cada árvore individual contribuem com um único voto indicando para qual classe cada instância dos dados de treinamento pertence. A classe mais frequente, ou seja, a mais votada, será a classe de informação final à qual a instância será atribuída (Figura 1) (HASTIE *et al.*, 2009; RODRIGUEZ-GALIANO *et al.*, 2012).

Figura 1 - Classificação usando Random Forest.



Fonte: SUN *et al.*, (2019).

Este algoritmo requer a definição de alguns parâmetros para gerar o modelo de predição: o número de árvores para formar a "floresta" ( $n\_estimators$ ) e o número de atributos/preditores considerados para cada nó nas árvores ( $max\_features$ ). Em outras palavras, o processo de classificação de um novo conjunto de dados envolve o uso de um conjunto fixo de variáveis preditivas aleatórias. Cada exemplo no conjunto de dados é classificado por  $n\_estimators$ , determinadas pelo usuário. A classe final atribuída a cada exemplo é determinada pelo valor mais frequente entre as  $n\_estimators$  geradas.

Além disso, o algoritmo permite avaliar a qualidade estatística através de um procedimento interno de amostragem chamado *out-of-bag* (oob), que pode ser usado para estimar erros de classificação. Para isso, cada subconjunto selecionado usando o *bagging* para o crescimento de cada árvore individual normalmente contém 2/3 do conjunto de dados de calibração. As amostras que não estão presentes no subconjunto de calibração são incluídas como parte de outro subconjunto chamado *out-of-bag* (oob), usadas para avaliar o modelo de RF (TSO; MATHER,

2009; RODRIGUEZ-GALIANO *et al.*, 2012). O RF é altamente sensível à seleção e ao tamanho das áreas de treinamento, e a máxima precisão é obtida quando as áreas de treinamento são distribuídas aleatoriamente, devem ser o mais amplas possível e devem ter uma autocorrelação espacial mínima (MILLARD; RICHARDSON, 2015).

Além de calcular o erro, as amostras oob permitem estimar a importância de cada característica no processo de classificação, com base na redução da precisão da classificação geral ou da classe quando a característica é permutada nas amostras oob (BREIMAN, 2001). Fornecendo ao RF a capacidade de selecionar eficientemente as melhores variáveis preditoras de um grande conjunto de características, contribuindo assim, na tomada de decisão.

Vários benefícios do uso do algoritmo RF têm se destacado, como saída de alta precisão, resiliência ao sobreajuste, além de permitir selecionar variáveis importantes, e assim, eliminar variáveis menos importantes (RODRIGUEZ-GALIANO *et al.*, 2012; BELGIU; DRAGUT, 2016; BREIMAN, 2001; BELGIU; DRAGUT, 2016; MAXWELL; WAGNER; FANG, 2018).

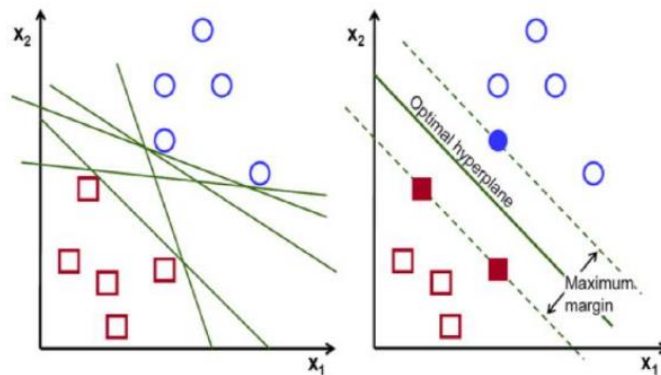
### **2.3.2. Support Vector Machine**

*Support Vector Machine* (SVM) (VAPNIK, 1995) é uma técnica de aprendizagem estatística não paramétrica supervisionada, que visa encontrar um hiperplano ótimo para resolver o problema de separação de classes. O termo hiperplano de separação ótima é usado para referir ao limite de decisão que minimiza erros de classificação, obtidos em etapas de treinamento, ou seja, maximiza a distância entre as amostras mais próximas (vetores de suporte) ao plano e efetivamente separa as classes, conforme mostrado na Figura 2 (HUANG; DAVIS; TOWNSHEND, 2002; MOUNTRAKIS; IM; OGOLE, 2011; YANG, 2011; QIAN *et al.*, 2015). Como resultado, a abordagem pode gerar alta precisão com pequenos conjuntos de dados de treinamento que reduzem os custos de aquisição de dados de treinamento, o que é considerado uma das vantagens de empregar o algoritmo.

Em sua forma mais simples, os SVM são classificadores binários lineares que atribuem a uma determinada amostra de teste uma classe de um dos possíveis dois rótulos, portanto, são obtidas baixas precisões para resolver um problema de limites de classes não lineares. Para isso, técnicas e soluções alternativas como o *Kernel-trick* são usados para resolver os problemas de inseparabilidades, usando uma função matemática adequada para mapear as correlações não lineares em um espaço dimensional superior (MOUNTRAKIS; IM; OGOLE, 2011; FASSNACHT

*et al.*, 2014). Este procedimento, permite criar um hiperplano que aparece não linear no espaço de recursos original.

Figura 2 - Estrutura de um classificador *Support Vector Machine*. À direita é ilustrado o hiperplano que maximiza a margem entre duas classes.



Fonte: MOUSTAFA *et al.*, (2020).

Apesar do SVM possuir quatro funções kernel principais: linear, quadrática, polinomial e função de base radial (RBF) (LORENA; CARVALHO, 2007), o kernel da função de base radial (RBF) é o parâmetro mais eficaz e comumente usado em classificações de imagens de sensoriamento remoto (KAVZOGLU; COLKESEN, 2009; WASKE *et al.*, 2010; QIAN *et al.*, 2015; NOI; KAPPAS, 2018; ADUGNA; XU; FAN, 2022; SAHITHI; KRISHNA; GIRIDHAR, 2022). O desempenho do classificador que utiliza o kernel RBF, pode ser influenciado por dois parâmetros: valor de penalidade ( $C$ ) e gama ( $\gamma$ ). O efeito de gama ( $\gamma$ ), um parâmetro que controla a largura do kernel, no modelo SVM usando o kernel RBF é semelhante ao  $C$ , pois se um valor alto for atribuído a ele, o modelo será superajustado e não generalizará bem (FOODY; MATHUR, 2004).

Além de ser um dos classificadores mais amplamente utilizado e robusto para a classificação de imagens de sensoriamento remoto (FOODY; MATHUR, 2004), o SVM possui várias vantagens. Por ser um algoritmo de aprendizado de máquina não paramétrico, ele lida eficientemente com conjuntos de dados multimodais com centenas de bandas/canais (WASKE *et al.*, 2010), ou seja, é insensível a problemas associados à dimensionalidade dos dados. Além da capacidade de aprender bem com um pequeno número de parâmetros, robustez frente a diferentes


tipos de variações e diversidade de modelos e eficiência computacional em relação a outros métodos (STEINWART; CHRISTMAN, 2008).

## 2.4. Iluminação

No contexto do sensoriamento remoto (SR), a iluminação direta refere-se a luz solar incidente que atinge a superfície terrestre sem sofrer dispersão atmosférica significativa. Essa condição resulta em reflexões intensas e sombras nítidas, afetando a resposta espectral dos objetos e influenciando as informações extraídas das imagens de SR (CHAVEZ, 1996). Por outro lado, a iluminação difusa ocorre quando a luz é espalhada e difundida pela atmosfera antes de atingir a superfície, resultando em uma distribuição mais uniforme da luz que, por sua vez, suaviza as características e detalhes da superfície. A iluminação difusa reduz contrastes entre objetos e minimiza a formação de sombras acentuadas (CAMPBELL, 2012).

Essas duas formas de iluminação desempenham papéis distintos na maneira como a radiação eletromagnética é refletida, absorvida ou transmitida pelos objetos, afetando a aparência e a interpretação das imagens adquiridas por sensores ópticos (Figura 3).

Figura 3 - Comparação dos efeitos da iluminação solar direta, iluminação atmosférica difusa, dispersão refletida dos objetos e radiação espalhada pela atmosfera em um dia ensolarado (A) e um dia com cobertura de nuvens (B).



Fonte: Modificado de Arroyo-Mora et al. (2021).



As sombras são um obstáculo, no sensoriamento remoto óptico de ambiente, visto que, os pixels que estão na sombra representam áreas que sofrem perturbações radiométricas, nas quais a aparência da superfície é modificada devido à ausência de iluminação direta (PONS; PADRÓ, 2019). Devido às condições de pouca luz, as sombras nas imagens de sensoriamento remoto degradam a qualidade da informação espectral e dificultam processos como extração e classificação de características, detecção de alterações e mosaico de imagens (LIU; YAMAZAKI, 2012).

Embora sombras sejam comumente confundidas com áreas iluminadas pelo sol em imagens de baixa resolução, a sua presença se torna mais problemática em imagens de alta resolução espacial. Isso é especialmente relevante no contexto de VANTs, que são capazes de capturar imagens com resoluções de poucos centímetros, tornando a remoção de sombras um desafio (MILAS *et al.*, 2017).

Geralmente, a radiação emitida por objetos na Terra atravessa a atmosfera e é captada por sensores de sensoriamento remoto. No entanto, a variabilidade dos sensores, os efeitos da atmosfera e as flutuações nas condições de iluminação nesse procedimento dificultam a obtenção precisa da refletância a partir dos valores de cinza (DN) dos sensores (CAO *et al.*, 2021).

No SR de imagem espectral, existem três metodologias aplicadas para recuperação da refletância: (1) o método Linear empírico (ELM), baseado em alvo conhecido, comumente usado no sensoriamento remoto aéreo (WANG; MYINT, 2015); (2) o modo de transferência radiativa da atmosfera (ARTM) que simula o processo de espalhamento, absorção e transmissão da radiação solar pela atmosfera, considerando as características da superfície e os efeitos atmosféricos, usado para correções radiométricas em imagens satelitais (HASHIMORO *et al.*, 2019) e; (3) o método de medição da radiação incidente (MIR) mede a irradiância incidente sincronizada com o processo de sensoriamento remoto, sendo mais conveniente para o sensoriamento aéreo ou terrestre (HONKAAVARA; KHORAMSHAHI, 2018).

Recentemente, sensores multiespectrais como o Rededge-M (MicaSense Inc., Seattle, WA, EUA) estão equipados com sensores de irradiância, como *Sensor de Luz de Downwelling* (DLS). Esses são capazes de medir a irradiância incidente enquanto capturam as imagens de radiância refletidas por objetos (MAMAGHANI; SALVAGGIO, 2019; CAO *et al.*, 2020). Além disso, os fabricantes de sensores VANT fornecem painéis de calibração para realizar correções radiométricas (WANG; MYINT, 2015).

Em resumo, refletância espectral de um material específico permanece constante, independentemente de estar em condições de sombreamento (recebendo apenas irradiância difusa) ou em condições não sombreadas (recebendo principalmente irradiância direta). O que varia é a radiância espectral refletida, pois a superfície recebe menos radiação total em condições de sombra, resultando em uma aparência mais escura (PONS; PADRÓ, 2019).

## **2.5. Altitude de voo**

A seleção da altitude de voo no sensoriamento remoto desempenha um papel crucial na captura de imagens de alta resolução e na determinação da área de cobertura. A altitude de voo afeta tanto a profundidade da atmosfera entre o sensor e o alvo quanto a resolução espacial das imagens (AASEN et al., 2018). Isto se deve ao fato de que a altitude de voo impacta diretamente na resolução das imagens do VANT, de forma que quanto maior a altitude de voo, menor é a resolução e vice-versa. No entanto, muitos estudos não fornecem justificativa ou suporte para as altitudes de voo operacional escolhidas, apesar de seu impacto significativo nas imagens (SINGH; FRAZIER, 2018).

Do ponto de vista da segurança, a altitude de voo precisa ser considerada seriamente porque o limite máximo de altitude de voo é definido pelas autoridades locais, enquanto a altitude mínima de voo depende de outros fatores, tais como os requisitos de precisão e a posição de descolagem do VANT. Em termos de produtividade, a quantidade de dados capturados e o tempo de processamento são inversamente proporcionais à altura do voo, e esses fatores também podem se correlacionar amplamente com a precisão (QUOC LONG et al., 2020). Portanto, uma investigação da influência da altura de voo do VANT na precisão da classificação da imagem é indispensável.

## **2.6. Medidas de Textura**

No contexto de Sensoriamento Remoto (SR), a textura refere-se à variação dos níveis de cinza dos pixels em uma imagem. A análise de textura é uma técnica para caracterizar a textura de uma imagem, que envolve o uso de métodos estatísticos para extrair informações sobre a variação espacial em uma área fixa (FENG *et al.*, 2015). Um dos métodos mais comumente utilizados na análise de textura é a matriz de coocorrência de níveis de cinza (*Gray Level Co-occurrence Matrix* – GLCM), proposto por Haralick, Shanmugam e Dinstein (1973).

A definição dada para matriz de coocorrência de níveis de cinza (Gray Level Co-occurrence Matrix – GLCM) é a de um método estatístico para descrição de texturas. A GLCM tem a característica de armazenar a probabilidade de que dois valores de intensidade de cinza estejam envolvidos por uma determinada relação espacial. A partir desta matriz de probabilidades diversas medidas estatísticas são retiradas, a fim de caracterizar a textura existente em uma imagem.

As estatísticas de textura derivadas a partir de GLCM são calculadas por meio das diferentes relações angulares e distância entre pares de células vizinhas (HARALICK *et al.*, 1973). O efeito de textura típico é a diferenciação entre superfícies ásperas e lisas, método que provou aumentar a precisão geral em imagens de resolução muito alta (FENG *et al.*, 2015; LALIBERTE *et al.*, 2009). Outras camadas de informação, como elevação e forma de objetos, têm sido usadas para complementar a separação de pixels ou segmentos (VAN DER WERFF & VAN DER MEER, 2008).

A GLCM é uma matriz simétrica e quadrada com o tamanho igual ao número de níveis de quantização da imagem, que registra a frequência de diferentes combinações de níveis de cinza presentes na imagem. Esse método é governado por três propriedades: (a) o tamanho do *kernel*, que representa a janela deslizante, (b) a direção  $\theta$  ( $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  e  $135^\circ$ ) e (c) a distância de deslocamento  $d$ . O tamanho da janela tem um impacto sobre o desempenho dos atributos texturais GLCM para a classificação do uso/cobertura do solo. Janelas pequenas podem amplificar diferenças e aumentar o conteúdo de ruído na imagem de textura, enquanto janelas maiores podem não efetivamente extrair informações de textura devido à suavização da variação de textura (LU *et al.*, 2012; ATTARCHI; GLOAGUEN, 2014).

A matriz é criada da seguinte maneira, após contar a ocorrência dos pares de pixels em um *kernel*, levando em consideração a distância ( $d$ ) e a direção ( $\theta$ ), a matriz GLCM é combinada com sua transposta para torná-la simétrica. Em seguida, essa matriz simétrica é normalizada, ou seja, seus valores são transformados em probabilidades ( $P_{ij}$ ), representando a probabilidade de ocorrência de um par de níveis de cinza em uma imagem. Após a normalização, várias métricas podem ser calculadas a partir da matriz GLCM e é aplicado a cada pixel, e ao final, uma nova imagem é gerada.

A análises de textura é uma das abordagens mais comuns usando características espaciais de uma imagem, visto que, um dos principais benefícios do uso de textura para melhorar a

classificação e mapeamento, é que as informações são extraídas da própria imagem, não sendo necessário dados suplementares (MISHRA *et al.*, 2018). As texturas têm sido usadas para várias aplicações, como estimativa de biomassa florestal, idade do povoamento, identificação de espécies vegetais e classificação de uso e cobertura do solo (KELSEY; NEFF, 2014; MENG *et al.*, 2016; EHLERS *et al.* 2022; WANG; ZHANG, 2014; GUO *et al.*, 2022; LIU, 2022; MISHRA *et al.*, 2018; VYJAYANTHI; ANJANA, 2020; PARK *et al.*, 2022).

## 2.7. Índices de Vegetação

Os Índices de Vegetação foram desenvolvidos com base em características específicas de absorção para medir indicadores biológicos e bioquímicos. Esses índices permitem combinar informações de diferentes bandas espectrais e podem compensar efeitos externos, como ângulos solares e de visão, além de efeitos internos, como variações no solo e nas condições topográficas (LIN *et al.*, 2015).

Os primeiros índices foram desenvolvidos para ressaltar a intensa reflectância da vegetação na região do infravermelho próximo (NIR), em comparação com sua absorção acentuada devido à presença de clorofila na região do espectro visível vermelho, como o Índice de Vegetação da Diferença Normalizada (NDVI) (ROUSE *et al.*, 1973).

Posteriormente, houve melhorias no desenvolvimento desses índices, como o VARI (*Visible Atmospherically Resistant Index*) (GITELSON *et al.*, 2002), que leva em consideração a resistência atmosférica na medição da reflectância das plantas, desenvolvido para mitigar os efeitos da atmosfera, como a absorção e dispersão da luz, que podem afetar a precisão das medições de vegetação. E o Índice de Vegetação Normalizada Verde (NDGI) (VERSTRAETE; PINTY; MYNENI, 1996) que substitui a banda vermelha pela banda verde, com o objetivo de aprimorar ainda mais a capacidade de detecção da vegetação em áreas urbanas e rurais, onde a reflectância pode ser mais significativa.

Além disso, o Índice de Vegetação Ajustado ao Solo Otimizado (GOSAVI) (RONDEAUX; STEVEN; BARET, 1996), que incorpora um coeficiente de ajuste do solo (0,16) para reduzir a sensibilidade do NDVI a variações no fundo do solo em uma ampla gama de condições ambientais. E o MSAVI2 (*Modified Soil-Adjusted Vegetation Index*) (QI *et al.*, 1994), uma variação do NDVI que leva em consideração a contribuição do solo na reflectância, proporcionando estimativas mais precisas em regiões com cobertura vegetal rala ou solo exposto.

Além disso, sensores multiespectrais mais recentes, permitiram o cálculo do Índice de Vegetação da Diferença Normalizada na Borda Vermelha (NDRE) (GITELSON; MERZLYAK, 1994), que utiliza a resposta espectral de uma banda localizada na região da borda vermelha, que é sensível a mudanças no teor de clorofila. De acordo com Hatfield *et al.* (2008), o uso dos canais verde e de borda vermelha evita a saturação e a perda simultânea de sensibilidade a certos valores de clorofila, além de serem geralmente preferidos por sua maior sensibilidade a teores moderados e elevados de clorofila.

### 3. MATERIAL E MÉTODOS

#### 3.1. Aquisição e pré-processamento de imagens de VANT

O conjunto de dados de VANT usado neste estudo foi coletado no câmpus da Universidade Federal de Lavras - UFLA, nos dias 07 de março e 09 de maio de 2023 entre 10h00 e 11h00. Foram coletadas imagens com diferentes combinações de iluminação e altitudes do voo. Dois níveis de iluminação, uniformemente claro (direto) e uniformemente nublado (difuso) foram controlados pela escolha do dia para os voos. E dois níveis de altura de voo (120 m e 150 m) foram controlados pela pré-programação de trajetórias de voo do VANT.

A aquisição de dados foi realizada utilizando um VANT quadricoptero DJI Matrice 100 (Figura 4), que consiste em uma plataforma multi rotor totalmente programável que pode ser personalizada com diferentes sensores para aplicações específicas, ao contrário de outros modelos disponíveis no mercado, como o DJI Phantom. A carga incluiu uma câmera multiespectral Micasense Rededge e um sensor de luz descendente (DLS) ou sensor de irradiância (Micasense, Seattle, WA, EUA).

Figura 4 - Equipamento de medição VANT DJI Matrice 100



Fonte: DJI Interprise

A câmera RedEdge-M da MicaSense (Figura 5), possui um sensor CMOS de 5 bandas capaz de capturar imagens simultaneamente em: azul (B) (475 nm, 20 nm de largura de banda), verde (G) (560 nm, 20 nm de largura de banda), vermelho (R) (668 nm, 10 nm de largura de banda), RedEdge (RE) (717 nm, 10 nm de largura de banda) e infravermelho próximo (NIR) (840 nm, 40 nm de largura de banda).

Além disso, o VANT conta com um sistema de posicionamento global (GPS), e sensor de luz solar *downwelling light sensor* (DLS), o qual registra as condições de luz ambiente durante o voo por todas as bandas e grava esta informação, que foi utilizada neste estudo para corrigir as

mudanças de iluminação em voos. Além disso, a câmera também tem interface com um Sistema de Navegação Global por Satélites (GNSS) integrado padrão que fornece informações de georreferenciamento e as coordenadas são armazenadas nos metadados de cada foto.

Figura 5 - Sensor RedEdge-M da MicaSense.



Fonte: Mytech

Os planejamentos dos voos foram realizados utilizando o software Pix4DMapper, com diferentes parâmetros de altitude (120 m e 150 m) e com sobreposição de imagem (*frontlap* e *sidelap*) ajustada para 80%. Imagens foram capturadas do painel de calibração (Micasense) antes e após cada voo para as correções radiométricas das imagens. Um modelo de conversão do fabricante transforma valores brutos de pixel em valores absolutos de radiância espectral, considerando a resolução radiométrica do sensor. As imagens do painel de calibração permitem calcular o fator de calibração de reflectância para cada banda, calculando a razão entre o valor de reflectância conhecido do painel de calibração do fabricante e a radiância média para pixels dentro do painel.

O pré-processamento das imagens foi realizado utilizando técnicas de reconstrução de imagem SfM (*Structure from Motion*) com o software livre WebODM, para a correção radiométrica e mosaico das imagens. As imagens processadas geraram ortomosaicos georreferenciados, com resolução espacial de 5 cm/pixel para o voo a 120 m de altitude e 8,6 cm/pixel para 150 m de altitude.

### 3.2. Método de pesquisa

A partir dos ortomosaicos gerados com as imagens obtidas com o VANT, uma análise de imagem orientada a objetos foi realizada para identificar as 7 classes de cobertura do solo consideradas neste trabalho, sendo elas: construções, árvores, grama, asfalto, calçadas, solo e

veículos. A análise das imagens foi baseada em objeto geográfico (GEOBIA), em função de sua adequação para imagens de alta resolução, além da capacidade de delimitar objetos e derivar métricas espectrais, espaciais e texturais (BLASCHKE, 2010; PEÑA *et al.*, 2014).

O processo de classificação consiste principalmente nas quatro etapas a seguir (Figura6: (1) segmentação de imagens e cálculo de atributos; (2) combinação de atributos, na qual oito esquemas foram desenvolvidos, onde S1–S7 foram organizados com base na combinação de atributos e S8 contém todos os atributos; (3) ajuste dos classificadores RF e SVM; (4) avaliação da acurácia dos modelos ajustados, em que precisão geral (OA, do inglês: *Overall Accuracy*), Índice Kappa e F1-Score são selecionados para avaliar a melhor abordagem de classificação; (5) avaliação da acurácia dos mapas, em que foram usados precisão do produtor, precisão do usuário, precisão geral e Kappa.

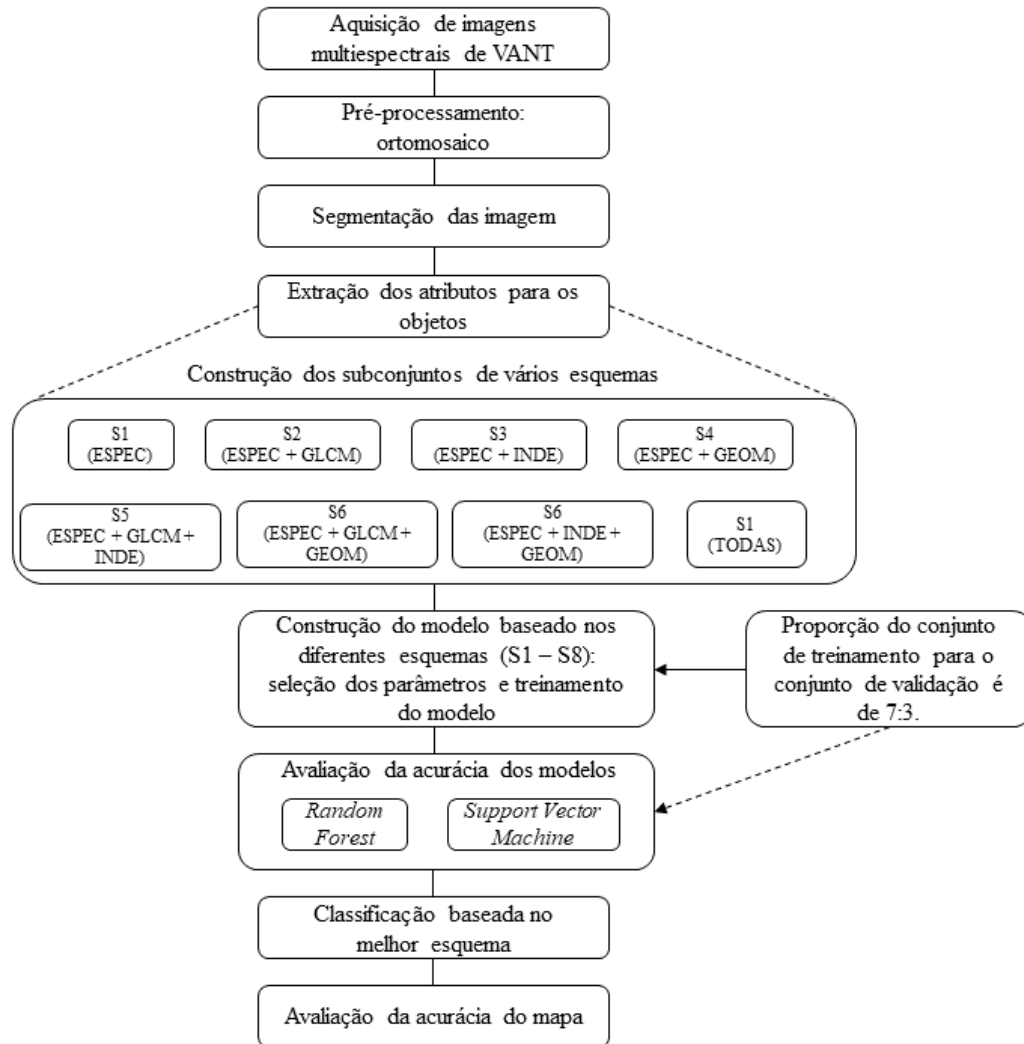
### 3.2.1 Segmentação de imagens

A primeira etapa na GEOBIA é a segmentação da imagem, o qual cria a partir do ortomosaico uma imagem particionada em segmentos não sobrepostos que possuem similaridade espectral no espaço e bandas multiespectrais (KALANTAR *et al.* 2017). A segmentação das imagens foi realizada por meio de um algoritmo baseado na técnica de crescimento de regiões, conhecida como *Multiresolution Segmentation* (MRS) (BAATZ; SCHAPE, 2000), utilizado o software eCognition Developer 9.

MRS é um algoritmo baseado em uma técnica de fusão de regiões. A partir de cada pixel forma-se um objeto de imagem que são mesclados para reduzir a heterogeneidade, produzindo objetos de imagem em vários níveis usando diferentes escalas de segmentação (BAATZ; SCHAPE, 2000; DU *et al.* 2016). O critério de fusão é a homogeneidade local, que descreve a semelhança entre objetos de imagem adjacentes.



Figura 6 - Fluxograma de trabalho.




Fonte: Do autor (2023).

O algoritmo depende de parâmetros como, pesos da camada da imagem (XIA; PERSELLO; KOEVA, 2019), parâmetro de escala, forma e compactação (TORRES-SÁNCHEZ; LÓPEZ-GRANADOS; PEÑA, 2015). Os pesos da camada da imagem definem a importância de cada camada da imagem para o processo de segmentação. O parâmetro de escala é o parâmetro mais importante, que controla o tamanho médio do objeto de imagem (DRAGUT, *et al.* 2014), quanto maior o valor maior será a heterogeneidade espectral dentro dos objetos de imagem, permitindo, portanto, mais pixels dentro de um objeto. O parâmetro de forma varia de 0 a 1,

indicando uma ponderação entre a forma do objeto e sua cor espectral. Um valor alto no parâmetro de forma significa que menos importância é dada às informações espectrais.

Os valores dos parâmetros de segmentação foram ajustados por meio de um procedimento de tentativa e erro, com base em uma avaliação visual, visto que, a interpretação visual é geralmente a forma mais significativa de parametrizar segmentações em ambientes naturais (RÄSÄNEN *et al.*, 2013). Para os ortomosaicos multiespectrais os valores dos parâmetros de escala, forma e compactidade foram definidos para 10, 0,4 e 0,7, respectivamente (Figura 7).

Figura 7 – Resultados da segmentação de ortomosaico multiespectral por meio do algoritmo *Multiresolution Segmentation* (MRS) e *Spectral Difference Segmentation* utilizando o software eCognition Developer 9.



Fonte: Do autor (2023).

Após a segmentação inicial, é necessário o agrupamento de objetos pertencentes à mesma classe, para isso foi utilizado o algoritmo *Spectral Difference Segmentation*, que realiza a fusão de objetos vizinhos que não excedam a diferença espectral máxima (ZYLSHAL *et al.*, 2016). Assim,

os objetos gerados na segmentação multiresolução foram mesclados para produzir os objetos finais, e o parâmetro foi igual a 2.

### 3.2.2 Extração das variáveis preditoras

Embora a maioria dos estudos de classificação do uso do solo conduzidos tenham utilizado apenas atributos espectrais e índices de vegetação, os atributos espaciais e geométricos também podem fornecer informações valiosas para melhorar os resultados. Portanto, para cada uma das imagens adquiridas baseada em combinações de luz (iluminação direta e difusa) e altitude do voo (120 m e 150 m) as variáveis espectrais, índices, espaciais e geométricas, foram extraídas e investigadas neste estudo.

As variáveis espectrais incluem a média ou desvio padrão das cinco bandas (azul, verde, vermelho, borda vermelha e infravermelho próximo), a diferença máxima e o valor geral de brilho, totalizando 12 no total. Enquanto as características de índice incluem NDVI, VARI, IFV e NDRE (Tabela 1).

Tabela 1 - Fórmula dos Índices de Vegetação.

Índices	Fórmula	Referência
NDVI	$\frac{(NIR - R)}{(NIR + R)}$	Rouse <i>et al.</i> (1973)
VARI	$\frac{(G - R)}{(G + R + B)}$	Gitelson <i>et al.</i> (2002)
NDRE	$\frac{(NIR - RE)}{(NIR + RE)}$	Gitelson; Merlyak (1994)
IFV	$\frac{2 \times G - R - B}{2 \times G + R + B}$	Louhaichi, Borman e Johnson (2001)

Fonte: Do autor (2023).

As variáveis espaciais, como índices de textura (Tabela 2), também podem melhorar os resultados da classificação (CONNERS, *et al.*, 1984). A textura refere-se à relação entre um pixel individual com seus pixels vizinhos e fornece informações valiosas para a classificação de uso e cobertura do solo. Medidas de textura de primeira ordem são resumos estatísticos dos valores dos pixels localizados dentro da unidade de análise. Medidas de textura de segunda ordem são derivadas da matriz de coocorrência de níveis de cinza (GLCM). A GLCM contém as frequências

normalizadas com as quais os valores de um par de pixels adjacentes coocorrem dentro da unidade de análise.

Tabela 2 - Fórmula e descrição das medidas de textura GLCM.

Métrica	Fórmula	Descrição
Média	$\sum_{i=0}^{quant_k} \sum_{j=0}^{quant_k} p(i,j) \times i$	Grau de regularidade da textura
Desvio Padrão	$\sqrt{\sum_{i=0}^{quant_k} \sum_{j=0}^{quant_k} p(i,j) \times (i - \text{média})^2}$	Desvio entre o valor de cinza do pixel e a média
Entropia	$\sum_{i=0}^{quant_k} \sum_{j=0}^{quant_k} p(i,j) \times \ln p(i,j)$	Mede o grau de desordem entre pixels na imagem
Homogeneidade	$\sum_{i=0}^{quant_k} \sum_{j=0}^{quant_k} p(i,j) \times \frac{1}{1 + (i + j)^2}$	Uniformidade da textura
Contraste	$\sum_{i=0}^{quant_k} \sum_{j=0}^{quant_k} p(i,j) \times (i - j)^2$	Mede o contraste com base na variação local do nível de cinza
Dissimilaridade	$\sum_{i=0}^{quant_k} \sum_{j=0}^{quant_k} p(i,j) \times  i - j $	Contraste de textura
Segundo momento angular	$\sum_{i=0}^{quant_k} \sum_{j=0}^{quant_k} p(i,j)^2$	Mede a uniformidade ou energia da distribuição do nível de cinza da imagem
Correlação	$\sum_{i=0}^{quant_k} \sum_{j=0}^{quant_k} \frac{(i - \text{média}) \times (j - \text{média}) \times p(i,j)^2}{\text{variância}}$	Mede a dependência linear dos níveis de cinza dos pixels vizinhos

Fonte: Do autor (2023).

Neste trabalho, utilizou-se a média (mean) e o desvio padrão (stdDev) como medidas de textura de primeira ordem, e as medidas propostas Haralick et al. (1973) que são entropia, homogeneidade, contraste, dissimilaridade, segundo momento angular e correlação como medidas de segunda ordem, totalizando 8 variáveis preditoras. Esses derivados são computados por meio de matrizes simétricas para pixels vizinhos, sendo que neste estudo, a abordagem utilizada foi em “todas as direções”, onde as somas de todas as quatro direções são calculadas a partir do cálculo da textura GLCM e foi usada a média das 5 bandas de entrada (RGB, NIR e RedEdge).

As variáveis geométricas (GEOM) incluem área, comprimento da borda, comprimento (Pxl), largura (Pxl), comprimento/largura, número de pixels, relação borda para borda da imagem, assimetria, índice de forma, arredondamento, índice de limite, número de pixels, compacidade, volume, ajuste de elipse, ajuste de retângulo, raio máximo da elipse, raio mínimo da elipse e encaixe retangular, totalizando 18 variáveis preditoras.

### 3.2.3. Construção de conjuntos para esquemas diferentes

Para entender os efeitos das diferentes variáveis preditoras no resultado da classificação, oito tipos de subconjuntos de variáveis foram construídos para formar oito esquemas de classificação diferentes neste estudo (Tabela 3). S1 contém apenas atributos espectrais, enquanto S2 (ESPEC + GLCM) e S3 (ESPEC + INDE) adicionam medidas de textura e índices de vegetação, respectivamente. S4 (ESPEC + GEOM) contém variáveis espectrais e geométricas, enquanto S5 (ESPEC + GLCM + INDE) e S6 (ESPEC + GLCM + GEOM) adiciona índices de vegetação e variáveis geométricas com base em S2, respectivamente. S7 (ESPEC + INDE + GEOM) adiciona variáveis geométricas baseados em S3 e S8 (Todos) inclui todos os tipos de características.

Tabela 3 - Subconjuntos de variáveis preditoras de vários esquemas.

ID dos esquemas	Subconjuntos de atributos	ESPEC	GLCM	INDE	GEOM	Total de atributos
S1	ESPEC	12				12
S2	ESPEC + GLCM	12	8			20
S3	ESPEC + INDE	12		4		16
S4	ESPEC + GEOM	12			18	30
S5	ESPEC + GLCM + INDE	12	8	4		24
S6	ESPEC + GLCM + GEOM	12	8		18	38
S7	ESPEC + INDE + GEOM	12		4	18	34
S8	Todas	12	8	4	18	42

Fonte: Do autor (2023).

### 3.2.4. Amostras de treinamento e verificação da precisão

De acordo com as diferentes categorias presentes na imagem, foi determinado um número amostral de 7 categorias. O número total para as diferentes categorias foi de 100 amostras. O método foi usado para construir o conjunto de dados de treinamento e verificação. A amostragem aleatória foi adotada para cada categoria na proporção de 7:3, dentre as quais a amostra de

treinamento (70%) foi usada para construir o modelo de classificação, e a amostra de verificação (30%) foi usada para verificar a precisão da classificação.

### 3.2.4 Métodos de Classificação

O RF é um método de aprendizado não paramétrico cujos resultados de classificação são determinados por múltiplas árvores de decisão. Comparado com outros classificadores, o RF tem as vantagens de ser menos propenso a *overfitting* e reduzir o impacto de outliers, levando a uma maior precisão da classificação em muitos estudos (GUO et al. 2022). Existem dois parâmetros importantes para o classificador de RF: o número de árvores de decisão ( $n\_estimators$ ) e o número de atributos contidos em cada árvore de decisão ( $max\_features$ ).

Inicialmente, testou-se os valores padrão, para todos os parâmetros, onde  $n\_estimators = 100$  e  $max\_features = \text{sqrt}$ , ou seja, é a raiz quadrada do número de variáveis. Em seguida, aumentou-se o valor de  $n\_estimators$  para 300, 500, 700 e 1000, mas mantendo o  $max\_features$  nos valores padrão (sqrt). Uma vez determinado o melhor valor de  $n\_estimators$ , este foi mantido constante e foi realizado novos experimentos para encontrar o melhor valor de  $max\_features$ , considerando uma faixa de magnitudes, ou seja,  $mtry = 10, 15, 20, 30, 40$  e 50.

Já o SVM é um classificador linear generalizado que realiza classificação binária em dados de acordo com o método de aprendizado supervisionado, e seu limite de decisão é o hiperplano de margem máxima que resolve a amostra de aprendizado. Realizou-se o teste com os valores de penalidade (C) variando de 50 a 2000, ou seja, testou-se uma faixa de valores (50, 100, 300, 600, 900, 1000, 1200, 1500, 1800) para determinar o valor ótimo de C, mantendo gama e outros valores constantes no seu valor padrão, e função de kernel linear. Os algoritmos foram executados utilizando a biblioteca gratuita Scikit-learn da linguagem de programação Python.

### 3.2.5 Avaliação da precisão do ajuste dos modelos

Para avaliar a precisão do ajuste do modelo, foram escolhidos o OA, Kappa e F1-Score que podem ser calculados com base na matriz de confusão. O OA é uma razão que representa o número de amostras classificadas corretamente para o número total, que está entre 0 e 1. Quanto mais próxima de 1 for a razão, melhor será o ajuste do modelo. O Kappa mede a consistência entre a categoria verdadeira e a prevista pelo modelo. Quanto maior o Kappa, melhor será o ajuste do modelo.

O F1-Score engloba de maneira abrangente tanto a taxa de *recall* quanto a taxa de precisão, sendo que uma alta taxa de *recall* indica uma maior propensão do modelo em classificar uma amostra como positiva. Por outro lado, uma alta taxa de precisão indica que o modelo é mais cauteloso em suas previsões. O F1-Score é um índice de avaliação médio ponderado que varia de 0 a 1. Quanto mais próximo o valor estiver de 1, maior será a precisão do modelo (GUO *et al.*, 2022). As métricas PA, UA e F1-score foram usadas para medir a qualidade dos modelos de classificação para cada classe de cobertura do solo. O PA indica a omissão de pixels para uma classe, o UA expressa a comissão de pixels e a pontuação F1 é a média harmônica entre o PA e o UA, então representa quão bem o modelo classifica cada classe (CHRISTOVAM *et al.*, 2019). As fórmulas são as seguintes:

$$OA = \frac{\sum_{i=1}^n P_{ii}}{N} \times 100$$

$$Kappa = \frac{N \sum_{i=1}^n P_{ii} - \sum_{i=1}^n (P_{i+} \times P_{+i})}{N^2 - \sum_{i=1}^n (P_{i+} \times P_{+i})}$$

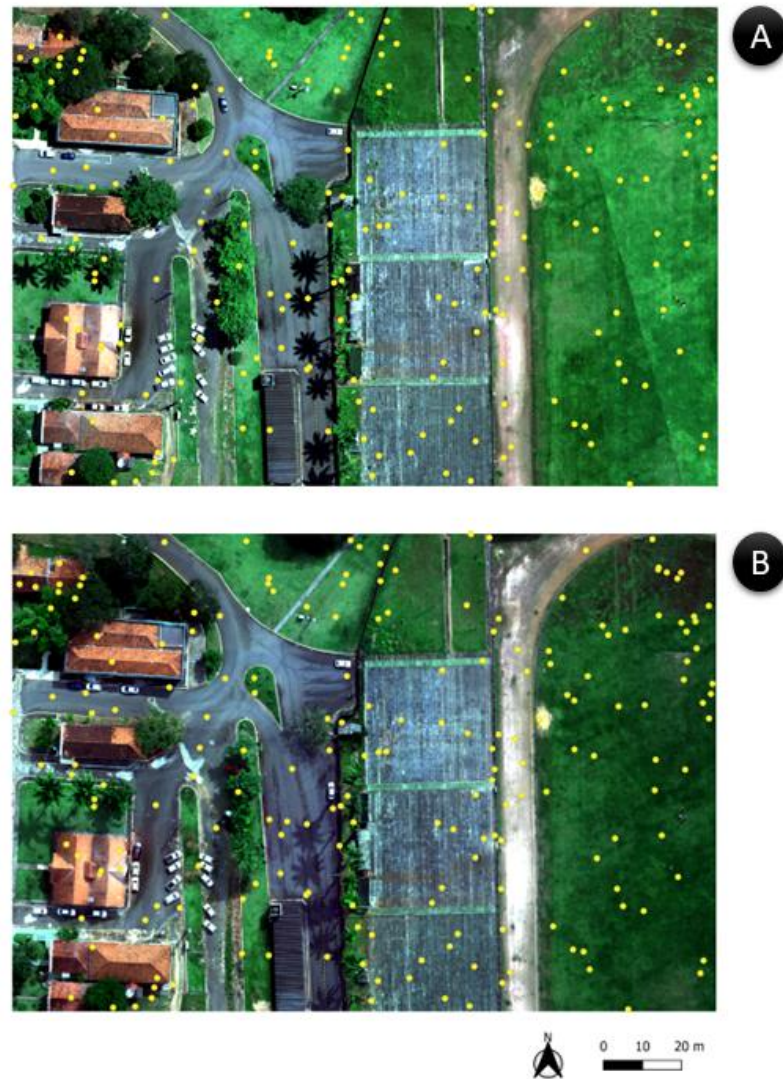
$$F1 = \frac{2 * UA * PA}{UA + PA}$$

Em que:  $n$  é o número total de classes,  $N$  é o número total de amostras de validação,  $P_{ii}$  é o número de amostras classificadas corretamente na na  $i$ -ésima linha e  $i$ -ésima coluna da matriz de confusão,  $P_{i+}$  e  $P_{+i}$  são o número total de amostras na  $i$ -ésima linha e  $i$ -ésima coluna, respectivamente.

### 3.2.6 Avaliação da precisão do mapa

Pontos aleatórios foram usados para verificação da precisão dos mapas classificados de cobertura do solo. Ao criar uma matriz de confusão para cada uma das classificações, a precisão do produtor (PA), do usuário (UA) e geral foi calculada, conforme fórmulas abaixo. Para verificação da precisão, 200 pontos de verificação interpretados visualmente foram selecionados aleatoriamente com base nas imagens originais do VANT (Figura 5).

Figura 8 - Pontos aleatórios para verificação da acurácia dos ortomosaicos obtidos com iluminação direta (A) e iluminação difusa (B).



Fonte: Do autor (2023).

PA denota o número de classificações corretas de uma categoria X para o número total de amostras de referência verdadeiras dessa categoria X, que reflete a razão da probabilidade de ser classificado corretamente. Enquanto, UA representa a razão entre o número de classificações corretas de uma categoria X e o número total de classificações dessa categoria nos resultados da classificação. A razão do número total de categorias é classificada como X.



$$PA = \frac{P_{ii}}{P_{i+}} \times 100$$

$$UA = \frac{P_{ii}}{P_{+i}} \times 100$$


Em que:  $n$  é o número total de classes,  $P_{ii}$  é o número de amostras classificadas corretamente na  $i$ -ésima linha e  $i$ -ésima coluna da matriz de confusão,  $P_{i+}$  e  $P_{+i}$  são o número total de amostras na  $i$ -ésima linha e  $i$ -ésima coluna, respectivamente.

## 4. RESULTADOS E DISCUSSÃO

### 4.1. Acurácia dos modelos

Os resultados da classificação indicam que o RF possui uma OA, Kappa e F1-score maior do que o SVM em todos os esquemas em cada uma das altitudes (120 m e 150 m) e iluminação (difusa e direta). Os algoritmos tiveram comportamentos semelhantes para as imagens capturadas a 120 m de altitude, tanto para iluminação direta (Figura 9) quanto para a iluminação difusa (Figura 10).

Figura 9 - A acurácia geral (OA) de classificação, índice Kappa e F1-score de diferentes classificadores e esquemas diferentes para a classificação da imagem adquirida a 120 m de altitude e iluminação direta.



Fonte: Do autor (2023).


O melhor resultado para o RF foi alcançado no esquema S8, com uma OA de 96,5%, Kappa de 0,95 e F1-score de 0,96 para a imagem obtida para iluminação difusa, e com uma OA de 96,18%, Kappa de 0,95 e F1-score de 0,96 a imagem obtida para iluminação direta. Enquanto para o SVM o melhor resultado foi alcançado no esquema S5, com uma OA de 89,8%, Kappa de 0,88 e F1-score de 0,90 para a imagem obtido para iluminação direta, e com uma OA de 90,73%, Kappa

de 0,89 e F1-score de 0,91 a imagem obtida para iluminação difusa. Portanto, pode-se observar que o algoritmo RF apresentou melhor desempenho na classificação de áreas urbanas.

Observa-se uma notável variação na precisão dos modelos de acordo com cada um dos esquemas, especialmente para o SVM. Ao analisar o gráfico (Figura 9) para a imagem obtida com iluminação direta, a adição de características de índice e textura nos esquemas S2, S3 e S5 aumentou a OA, em 3,90%, 5,37% e 7,32%, respectivamente. Enquanto as características geométricas nos esquemas S4, S6 e S7, diminuiu a OA em 10,24%, 6,34% e 6,34%, respectivamente.

Padrão semelhante foi observado (Figura 10) na imagem obtida com iluminação difusa, onde a adição de características de índice e textura nos esquemas S2, S3 e S5 levou a um aumento da OA do SVM em 2,93%, 4,39% e 8,29%, respectivamente. No entanto, a inclusão de características geométricas nos esquemas S4, S6 e S7 resultou em uma diminuição da OA em 9,27%, 7,32% e 6,83%, respectivamente.

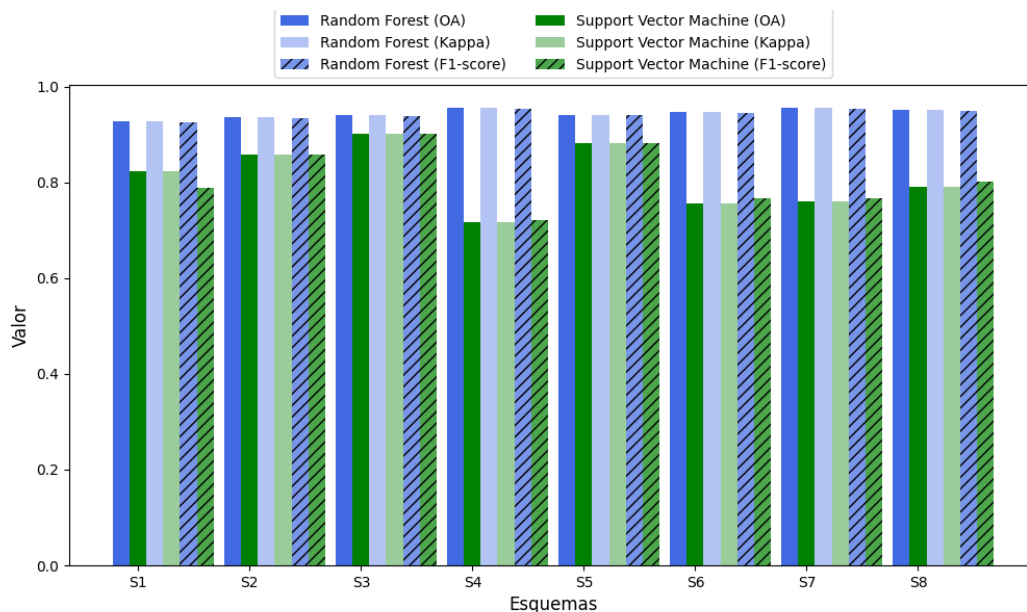
Figura 10 - A acurácia geral de classificação, índice Kappa e F1-score de diferentes classificadores e esquemas diferentes para a classificação da imagem adquirida a 120 m de altitude e iluminação difusa.



Fonte: Do autor (2023).

Por outro lado, para a imagem obtida a 150 m de altitude com iluminação direta (Figura 11), o RF obteve seu melhor desempenho no esquema S4, com uma OA de 95,6%, Kappa de 0,96 e F1-score de 0,95. Enquanto, o SVM alcançou seu melhor resultado no esquema S3, com uma Precisão Global (OA) de 90,2%, um coeficiente Kappa de 0,88 e um F1-score de 0,90.

Figura 11 - A acurácia geral de classificação, índice Kappa e F1-score de diferentes classificadores e esquemas diferentes para a classificação da imagem adquirida a 150 m de altitude e iluminação direta.



Fonte: Do autor (2023).


Enquanto, para a imagem obtida a 150 m de altitude com iluminação difusa (Figura 12), o RF obteve seu melhor desempenho no esquema S6, com uma OA de 97,1%, Kappa de 0,96 e F1-score de 0,97. Enquanto, o SVM alcançou seu melhor resultado no esquema S5, com uma OA de 90,7%, um coeficiente Kappa de 0,89 e um F1-score de 0,91.

Assim como foi observada uma variação significativa da OA do SVM em relação às características espectrais, índices e geométricos para as imagens obtidas a uma altitude de 120 m. Esse padrão também se mantém para as imagens obtidas a 150 m de altitude, independentemente do tipo de iluminação. Os esquemas S2, S3 e S5 mostraram um aumento na OA de 3,41%, 7,80% e 5,85%, respectivamente, ao adicionar características de índice e textura à imagem obtida para

iluminação direta (Figura 11). Em contraste, a inclusão de características geométricas nos esquemas S4, S6 e S7 resultou em uma diminuição da OA em 10,73%, 6,83% e 6,34%, respectivamente.

De forma semelhante, na imagem obtida para iluminação difusa (Figura 12), houve um aumento na OA do SVM em 2,3%, 7,32% e 7,80% ao adicionar características de índice e textura nos esquemas S2, S3 e S5, respectivamente. No entanto, a inclusão de características geométricas nos esquemas S4, S6 e S7 levou a uma diminuição da OA em 9,27%, 7,80% e 6,83%, respectivamente.

Figura 12 - A acurácia geral de classificação, índice Kappa e F1-score de diferentes classificadores e esquemas diferentes para a classificação da imagem adquirida a 150 m de altitude e iluminação difusa.



Fonte: Do autor (2023).

Analisando as mudanças na precisão para cada um dos casos, pode-se perceber que diferentes conjuntos de características têm efeitos diferentes na precisão. A adição de características de índice e textura nos esquemas S2, S3 e S5 aumentou a OA do SVM, entretanto, ao introduzir características geométricas nos esquemas S4, S6 e S7, a OA diminuiu. Demonstrando que características de índice e textura têm um impacto positivo na OA, enquanto características

geométricas têm um impacto negativo na OA. Pode-se notar esse comportamento para as diferentes altitudes e iluminação.

Em um estudo conduzido por Guo *et al.* (2022), para identificação de árvores urbanas, os autores observaram que a inclusão de características de índice e textura com base em S2 e S3 resultou em um aumento de 5,4% e 2,5% na OA, respectivamente. Porém, ao introduzir características geométricas baseadas em S2 e S3, a OA diminuiu em 0,6% e 0,1%, respectivamente, reforçando os achados deste estudo para o SVM. Entretanto, Guo *et al.* (2011) revelaram em seus experimentos de classificação que o melhor conjunto de características deve ser uma combinação de informações geométricas e espectrais.

#### **4.2. Importância das características**


Os resultados sobre a importância das características revelam que diferentes tipos de características desempenham papéis distintos na classificação de áreas urbanas. Ao analisar os diferentes esquemas de ajustes, as características espectrais mostraram-se as mais relevantes para todas as imagens. Notou-se que quando um esquema inclui tanto características espectrais quanto características de textura entre as 15 características mais importantes, o número de características espectrais é sempre maior do que o número de características de textura, indicando que as características espectrais têm uma importância relativa maior.

As características de índices são menos importantes do que as características espectrais e texturais, embora estejam presentes nos esquemas S3, S5, S7 e S8, sempre apresenta os menores valores de importância. Já as características geométricas são as menos importantes entre as quatro selecionadas, pois em S8 não têm características geométricas entre as 15 mais importantes. Portanto, entre os quatro tipos de características, as espectrais são as mais importantes, seguidas pelas de textura, índice e geométricas.

Embora a primeira posição tenha variado entre os esquemas para a imagem adquirida a 120 m de altitude com iluminação direta (Figura 13), é evidente que as variáveis Standard\_d\_4 (S5) e GLCM\_Ang\_2 (S8) foram as características mais importantes para discriminar as diferentes coberturas do solo para o SVM e RF, respectivamente. Visto que, esses esquemas obtiveram os melhores resultados para cada um dos algoritmos. Além disso, as características Brightness (ESPEC), Mean\_Red (ESPEC), Mean\_RedEd (ESPEC), GLCM\_StDe (GLCM), Volume\_Pxl

(GEOM) e GLCM\_Contr (GLCM), também apresentaram importância entre as 15 características mais importantes.

Figura 13 - Resultados de importância das variáveis de acordo com cada um dos esquemas (S1 a S8) para imagem adquirida a 120 m de altitude e iluminação direta.




Fonte: Do autor (2023).

Apesar dos algoritmos apresentarem comportamentos semelhantes para as imagens capturadas a 120 m de altitude, a importância das variáveis dentro dos esquemas mostrou-se ligeiramente diferente. Na imagem com iluminação direta (Figura 13), as características espectrais ocuparam a primeira posição em quatro esquemas (S1, S2, S3 e S5), enquanto na imagem com iluminação difusa (Figura 14), foram três esquemas (S1, S3 e S8).

De todo modo, mesmo para a imagem adquirida a 120 m de altitude com iluminação difusa (Figura 14) nota-se que as características espectrais têm uma importância maior em relação às características texturais, pois, no caso do esquema S8 que contém todas as variáveis, o Standard\_d (ESPEC) ocupou a primeira posição, tornando-se o melhor esquema para o RF. Por outro lado, a característica GLCM\_Ang\_2 (S5) foi a mais importante para discriminar as diferentes coberturas

do solo para o SVM. Além disso, as características Brightness (ESPEC), GLCM\_Dissi, Mean\_Red (ESPEC) e Width\_Pxl (GEOM) também estão classificadas entre as 15 características mais importantes, reforçando sua relevância nos resultados do estudo.

Figura 14 - Resultados de importância das variáveis de acordo com cada um dos esquemas (S1 a S8) para imagem adquirida a 120 m de altitude e iluminação difusa.



Fonte: Do autor (2023).


Em relação à imagem adquirida a 150 m de altitude com iluminação direta (Figura 13), a importância das variáveis dentro dos esquemas se comportou de maneira semelhante ao observado nas imagens anteriores. As características espectrais ocuparam a primeira posição nos esquemas S1, S2, S3 e S5, enquanto as características texturais estiveram em destaque nos esquemas S6 e S8, e, por fim, as características geométricas dominaram os esquemas S4 e S7.

No entanto, o RF obteve seu melhor desempenho no esquema S4, onde as variáveis Length\_Pxl (GEOM) e Volume\_Pxl (GEOM) foram as mais importantes, contradizendo o padrão anterior em que as características espectrais e texturais eram mais relevantes nos modelos com maior acurácia. Por outro lado, a característica Brightness (ESPEC) se mostrou a mais importante no esquema S5, onde o SVM alcançou seu melhor desempenho. Além disso, as características



Standard\_d\_4 (ESPEC), Mean\_Green (ESPEC), GLCM\_Corre e Border\_len (GEOM) também se destacaram, ocupando a primeira posição entre as 15 características mais importantes.

Figura 15 - Resultados de importância das variáveis de acordo com cada um dos esquemas (S1 a S8) para imagem adquirida a 150 m de altitude e iluminação direta.




Fonte: Do autor (2023).

Em contrapartida, embora a primeira posição ainda varie entre os esquemas para a imagem adquirida a 150 m de altitude com iluminação difusa (Figura 15), é evidente que as variáveis GLCM\_Corre (S5) e Standard\_d\_2 (S6) foram as características mais importantes para discriminar as diferentes coberturas do solo para o SVM e RF, respectivamente.

Esses esquemas obtiveram os melhores resultados para cada um dos algoritmos, mantendo o padrão observado nas imagens adquiridas a 120 m de altitude, em que as características espectrais e texturais eram mais relevantes nos modelos com maior acurácia. Ademais, as características Brightness (ESPEC), Standard\_d\_1 (ESPEC), Area\_Pxl (GEOM), Length\_Pxl (GEOM) e Mean\_Green (ESPEC) também se destacaram, ocupando a primeira posição entre as 15 características mais importantes para os diferentes esquemas.

Figura 16 - Resultados de importância das variáveis de acordo com cada um dos esquemas (S1 a S8) para imagem adquirida a 150 m de altitude e iluminação difusa



Fonte: Do autor (2023).

Em estudo Liu *et al.* (2019), para mapeamento LULC usando dados ópticos e SAR do Sentinel concluíram que a análise GEOBIA supera os algoritmos baseado em pixels, principalmente pela possibilidade de obter mapas temáticos baseados em objetos em vez de utilizar atributos texturais, uma vez que, as texturas GLCM não foram importantes (menos de 2%) para a classificação estimada por RF, sendo as características espectrais as mais importantes.

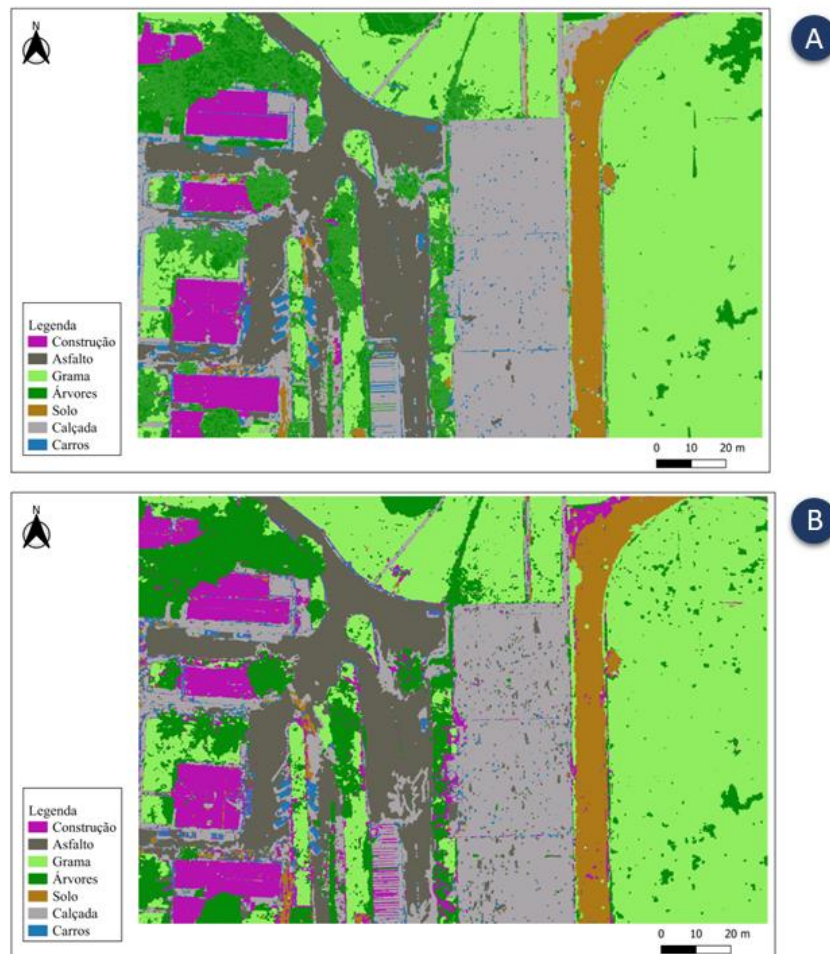
Enquanto Park *et al.* (2022), calculando a importância da variável, as variáveis mais influentes foram avaliadas na ordem do modelo de superfície digital normalizado (nDSM), índice de vegetação de diferença normalizada (NDVI), temperatura da superfície terrestre (LST), índice de vegetação ajustado ao solo (SAVI), azul, verde, vermelho, reledge.

### 4.3. Classificação e avaliação de precisão

Os mapas de classificação da área de estudo para cada classificador (RF e SVM) e em cada uma das altitudes (120 m e 150 m) e iluminação (difusa e direta) com base no melhor esquema mostra que o classificador RF tem um desempenho superior, conforme Figura 17, 18, 19 e 20. A

partir da classificação das imagens foram geradas matrizes de confusão (Apêndice 5, 6, 7 e 8) para a avaliação da precisão, e calculado os valores do coeficiente Kappa e a precisão geral para os algoritmos de classificação RF e SVM, em cada um dos voos com diferentes altitudes e iluminação, os quais foram compilados nas Tabelas 4 e 5, para melhor compreensão.

Figura 17 - Resultado da classificação para os algoritmos RF (A) e SVM (B) baseado no melhor esquema para a imagem adquirida a 120 m de altitude e iluminação direta.



Fonte: Do autor (2023).

Com base em 200 pontos aleatórios de validação nas imagens adquiridas a 120 de altitude (Tabela 4), a precisão do usuário para a classe asfalto é de 70% (iluminação direta) e 66,67% (iluminação difusa) para o RF, enquanto para SVM é de 56,67% para as duas iluminações. Para a grama, a precisão do usuário para o classificador RF está entre 60% (iluminação direta) e cerca

66,67% (iluminação difusa), e para SVM é cerca de 66,67% (iluminação direta) e 64,44% (iluminação difusa).

Tabela 4 – Acurácia para os algoritmos RF e SVM baseado no melhor esquema para as imagens adquirida a 120 m de altitude.

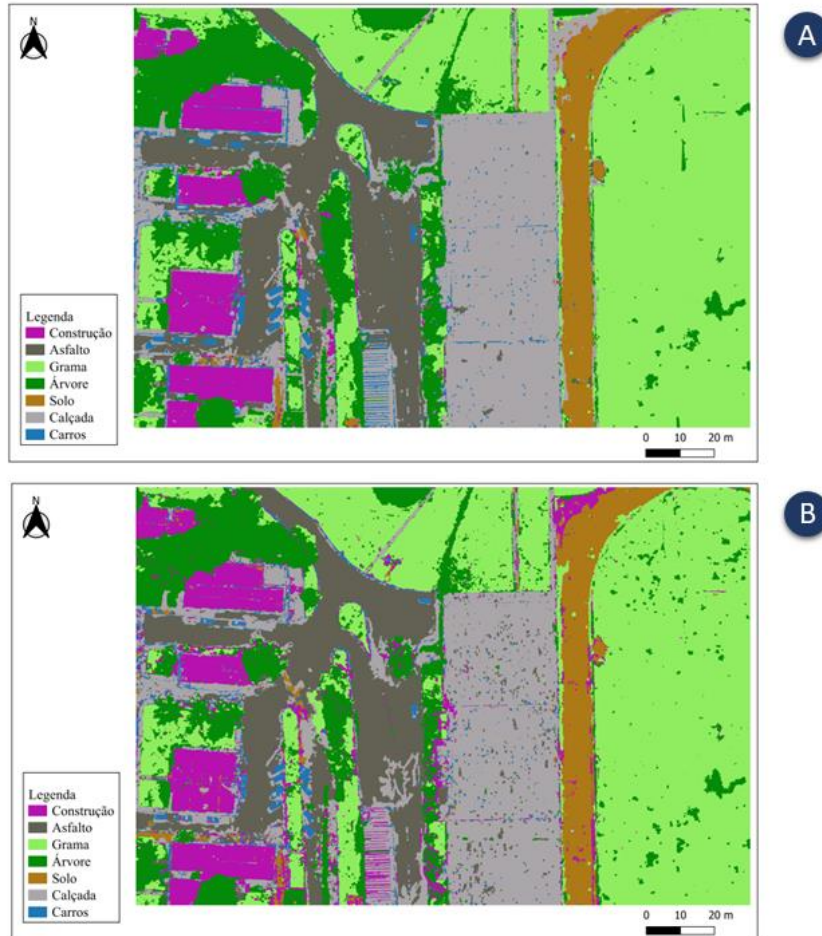
Classes	Iluminação direta				Iluminação difusa			
	<i>Random Forest</i>		<i>Support Vector Machine</i>		<i>Random Forest</i>		<i>Support Vector Machine</i>	
	UA	PA	UA	PA	UA	PA	UA	PA
Construção	92,86	76,47	100,00	56,00	92,86	76,47	100,00	53,85
Asfalto	70,00	95,45	56,67	73,91	66,67	95,24	56,67	73,91
Gramma	60,00	93,10	66,67	93,75	66,67	93,75	64,44	90,63
Árvore	90,00	64,29	87,50	68,63	90,00	69,23	87,50	68,63
Solo	96,77	100,00	83,87	96,30	96,77	100,00	80,65	100,00
Veículos	92,86	81,25	92,86	100,00	85,71	80,00	92,86	92,86
Calçada	80,77	70,00	69,23	62,07	84,62	66,67	65,38	58,62
<b>AO</b>	80,50		76,50		81,50		75,00	
<b>Kappa</b>	0,77		0,72		0,78		0,70	

Fonte: Do autor (2023).

Por outro lado, analisando a acurácia do produtor, para o voo com iluminação direta (Tabela 4), os valores para o RF são de 95,45% e 93,10%, já para o voo com iluminação difusa (Tabela 4), a acurácia do produtor para o RF é de 95,24% e 93,75%, para asfalto e grama, respectivamente. Enquanto para SVM são de 73,91% para asfalto nas duas imagens, para grama é 90,63% (iluminação difusa) e 93,75% (iluminação direta).

A classe calçada é classificada com uma acurácia do usuário de 80,77% (iluminação direta) e 84,62% (iluminação difusa) para RF, e 69,23% (iluminação direta) e 65,38% (iluminação difusa) para SVM. A precisão do produtor chega a 70,00% (iluminação direta) e 67,67% (iluminação difusa) com RF, e 62,07% (iluminação direta) e 58,62% (iluminação difusa) para SVM.

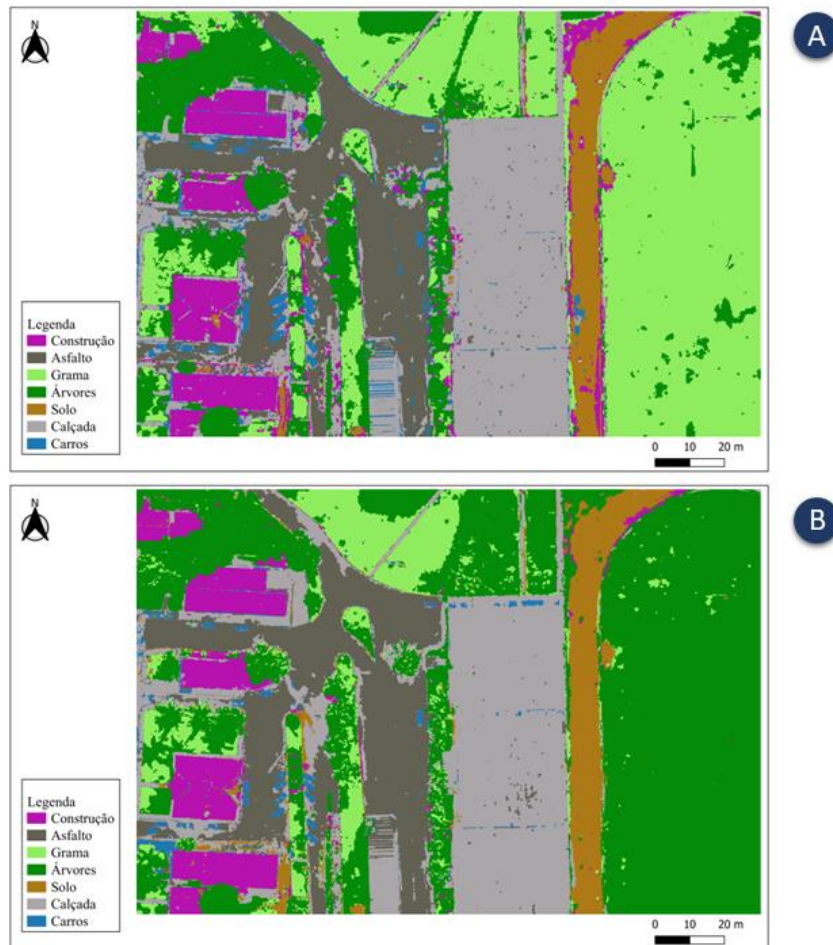
Figura 18 - Resultado da classificação para os algoritmos RF (A) e SVM (B) baseado no melhor esquema para a imagem adquirida a 120 m de altitude e iluminação difusa.



Fonte: Do autor (2023).

A precisão geral é de 81,50% para o RF e 75,00% para SVM na imagem com iluminação difusa (Tabela 4), com valores Kappa variando de 0,78 a 0,70 para o RF e SVM, respectivamente. A precisão geral para o mosaico com iluminação direta (Apêndice 5) é de 80,50% para o RF e 76,5% para SVM, com valores de Kappa em torno de 0,77 para RF e 0,72 para SVM.

Figura 19 - Resultado da classificação para os algoritmos RF (A) e SVM (B) de classificação baseado no melhor esquema para a imagem adquirida a 150 m de altitude e iluminação direta.



Fonte: Do autor (2023).

Para as imagens adquiridas a 150 m de altitude (Tabela 5), a precisão do usuário para a classe asfalto é de 66,67% para ambas as condições de iluminação para o RF. Já ao usar SVM, a precisão é de 60,00% com iluminação direta e de 56,67% com iluminação difusa. Em relação à classe grama, o classificador RF apresenta uma precisão do usuário entre 55,56% (iluminação direta) e cerca de 68,89% (iluminação difusa). Para o SVM, a precisão é de aproximadamente 71,11% (iluminação difusa) e de 17,78% (iluminação direta). A baixa precisão do SVM pode ser

observada na Figura 19, visto que, classificou erroneamente todo o campo de futebol como árvores, ao invés de grama.

Tabela 5 – Acurácia para os algoritmos RF e SVM baseado no melhor esquema para as imagens adquirida a 150 m de altitude.

Classes	Iluminação direta				Iluminação difusa			
	<i>Random Forest</i>		<i>Support Vector Machine</i>		<i>Random Forest</i>		<i>Support Vector Machine</i>	
	UA	PA	UA	PA	UA	PA	UA	PA
Construção	92,86	56,52	85,71	66,67	92,86	68,42	100,00	63,64
Asfalto	66,67	95,24	60,00	81,82	66,67	95,24	56,67	70,83
Grama	55,56	96,15	17,78	72,73	68,89	100,00	71,11	88,89
Árvore	90,00	63,16	85,00	47,22	95,00	73,08	87,50	72,92
Solo	96,77	100,00	87,10	96,43	93,55	100,00	80,65	96,15
Veículos	71,43	83,33	85,71	80,00	85,71	85,71	92,86	92,86
Calçada	84,62	70,97	80,77	61,76	80,77	61,76	65,38	56,67
<b>AO</b>	78,00		66,00		82,00		0,79	
<b>Kappa</b>	0,74		0,60		76,50		0,72	

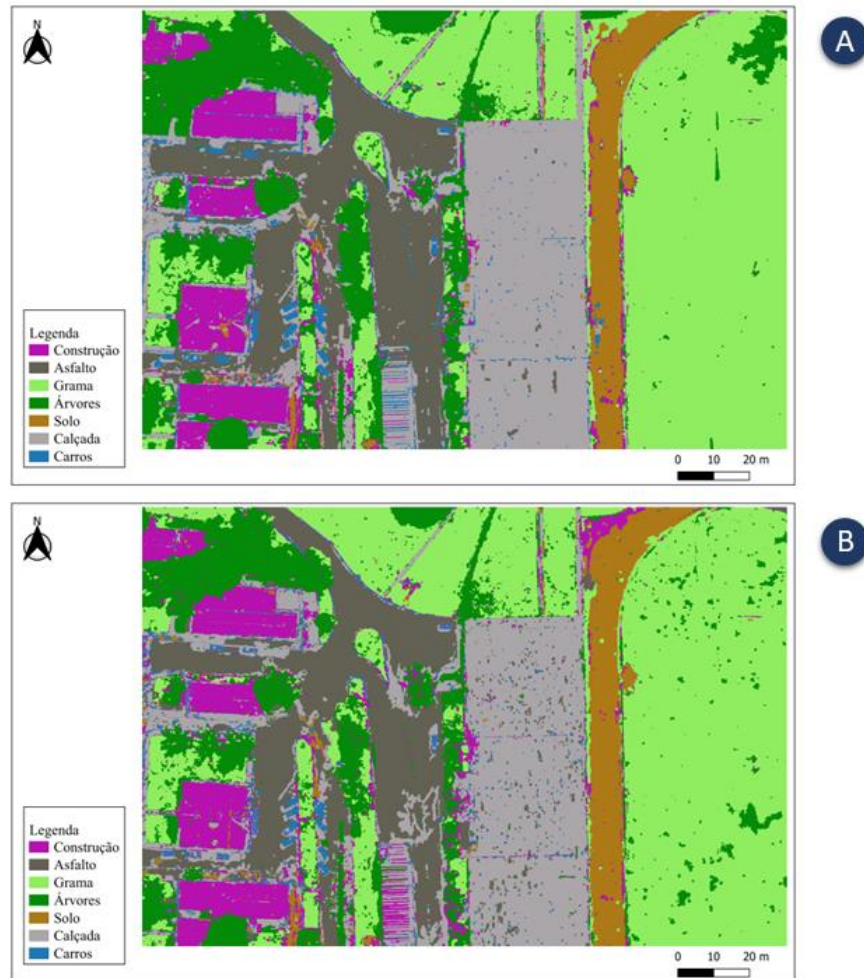
Fonte: Do autor (2023).

Analisando a acurácia do produtor, considerando o voo com iluminação direta a 150 m de altitude (Tabela 5), os valores de acurácia para o classificador RF são de 95,24 % para asfalto e 96,15% para grama. Já no voo com iluminação difusa (Tabela 5), a acurácia do produtor para o RF é de 95,24% para asfalto e 100% para grama. Enquanto para o SVM, a acurácia é de 81,82% para asfalto e 72,73% para grama (iluminação direta), e de 70,83% para asfalto e 88,89% para grama (iluminação difusa).

A acurácia do usuário para a classe calçada é de 84,62% com iluminação direta e 80,77% com iluminação difusa, para o RF. Enquanto para SVM, a acurácia é de 80,77% com iluminação direta e 65,38% com iluminação difusa. A precisão do produtor é de 70,97% (iluminação direta) e 61,76% (iluminação difusa) com RF, e 61,76% (iluminação direta) e 56,67% (iluminação difusa) para SVM.

A precisão geral é de 82,00% para o RF e 76,5% para SVM na imagem com iluminação difusa (Tabela 5), com valores Kappa variando de 0,79 a 0,72 para o RF e SVM, respectivamente. A precisão geral para a imagem com iluminação direta (Tabela 5), é de 78,00% para o RF e 66% para SVM, com valores de Kappa em torno de 0,74 para RF e 0,60 para SVM.

Figura 20 - Resultado da classificação para os algoritmos RF (A) e SVM (B) de classificação baseado no melhor esquema para a imagem adquirida a 150 m de altitude e iluminação difusa.



Fonte: Do autor (2023).

Em geral, a qualidade da classificação pode ser considerada boa, levando em conta os erros inerentes à imagem. Isso é confirmado pelo coeficiente Kappa, cujos valores variaram de 0,74 a 0,79 RF e de 0,60 a 0,72 para SVM, revelando que o algoritmo RF apresentou melhor desempenho do que SVM. Isso é consistente com muitos resultados de pesquisas que indicam que RF tem maior precisão do que SVM (CHRISTOVAM *et al.*, 2019; LUCA *et al.*, 2019; ADUGNA; XU; JUNLING, 2022; GUO *et al.*, 2022).

Como resultado da análise quantitativa da classificação da cobertura do solo, nota-se que as árvores foram bem distinguidas, entretanto, houve uma tendência de classificar grama como



árvore. Foi constatado que construção, solo, asfalto e veículos foram bem classificados, entretanto, houve uma tendência de classificar algumas áreas de asfalto como calçadas.

A tendência em classificar erroneamente, grama como árvores e asfalto como calçadas, deve-se a semelhanças nas assinaturas espectrais desses objetos. Além disso, as sombras são um dos problemas mais comuns que dificultam a extração precisa de dados em análises de sensoriamento remoto e estudos adicionais sobre detecção e correção de sombras são necessários (MILAS *et al.*, 2017; PONS; PADRÓ, 2019).

Outros autores também enfrentaram desafios com a presença de sombras, ao realizar a classificação da ocupação do solo em uma floresta de sobre, para voos no período de primavera e verão. Evidenciando a necessidade de um planejamento dos horários dos voos, visto que a imagem do verão foi afetada por cerca de 30% a mais de área sombreada do que a da primavera (LUCAS *et al.* 2019).

Enquanto, Ruwaimana *et al.* (2018) encontraram uma classificação melhorada das espécies de mangue a partir de ortomosaicos RGB adquiridos sob condições nubladas, em comparação com imagens de satélites de alta resolução espacial. Isso se deve ao brilho reduzido da água e à iluminação homogênea com sombras mínimas.

Além disso, avaliando o impacto da iluminação nas imagens hiperespectrais sob várias condições de cobertura de nuvens, concluíram que as condições de iluminação difusa, podem ser benéficas para revelar características espectrais na vegetação que são obscurecidas pela reflectância predominantemente não Lambertiana observada sob alta iluminação direta. (ARROYO-MORA *et al.* 2021). Corroborando com o presente trabalho, visto que, o melhor desempenho do RF foi usando as imagens obtidas com iluminação difusa para as altitudes de 120 m e 150 m, com precisão geral de 81,50% e de 82,00%, respectivamente.

Conforme sugerido por Singh e Frazier (2018) a maioria dos estudos não forneceu nenhuma justificativa ou suporte para a altitude de voo operacional, por mais que esse parâmetro afete a resolução espacial das imagens adquiridas. Flores-de-Santiago *et al.* (2020) avaliando o efeito da altitude de voo e sobreposição para gerar um ortomosaico em zonas costeiras, encontraram o voo ideal a 120 m de altitude com sobreposição de 60/50%. Enquanto Awais *et al.* (2021), avaliando a altura e tempo ideais de voo usando imagens de VANT na agricultura de precisão, obtiveram melhores resultados com ortomosaicos de 60 m de altitude.

Swaze *et al.* (2022), avaliando como a altitude e a velocidade de voo do VANT influenciam as previsões do modelo de biomassa florestal acima do solo, concluíram que há uma forte relação entre a altitude de voo e a precisão da modelagem, com ganhos com a aquisição entre 80 e 120 m. Fraser e Congalton (2018) testaram o efeito da altitude de voo no alinhamento da imagem e descobriu que voar na altitude mais alta testada forneceu os melhores resultados. Corroborando com o presente estudo, em que o melhor resultado para RF foi obtido usando o esquema S6 para a imagem obtida a 150 m de altitude e iluminação difusa.

## CONCLUSÃO

1. Quanto aos parâmetros de altitude de voo e luminosidade, ficou evidente a sua relevância na classificação do uso e cobertura do solo. Diante o exposto, conclui-se que os melhores parâmetros são 150 m de altitude sob iluminação difusa para a classificação do uso e cobertura do solo na área de estudo considerada.
2. A comparação entre os algoritmos *Random Forest* (RF) e *Support Vector Machine* (SVM) revelou que o classificador RF superou o SVM em todos os esquemas avaliados. Isso sugere que o RF é uma opção mais eficiente para a classificação de imagens multiespectrais na área de estudo.
3. A análise da importância das diferentes métricas na classificação das imagens mostrou que as características espectrais foram as mais relevantes em todas as imagens avaliadas, portanto, desempenham um papel fundamental na discriminação das diferentes classes de uso e cobertura do solo.
4. Ao avaliar a metodologia mais adequada para a classificação de imagens na área em estudo, verificou-se que o classificador *Random Forest* obteve a maior precisão ao combinar as características espectrais, texturais e geométricas para a imagem obtida a 150 m de altitude sob iluminação difusa. Essa combinação demonstrou-se mais eficaz em termos de acurácia, reforçando a importância da integração de atributos contextuais dos objetos na imagem para melhorar os resultados de classificação.

## REFERÊNCIA BIBLIOGRÁFICA

ADUGNA, T.; XU, W.; FAN, Ji. **Comparison of Random Forest and Support Vector Machine Classifiers for Regional Land Cover Mapping Using Coarse Resolution FY-3C Images.** *Remote Sensing*, v. 14, n. 3, p. 574, 2022.

AL-NAJJAR, H.A.H. et al. **Land cover classification from fused DSM and UAV images using convolutional neural networks.** *Remote Sensing*, v. 11, p. 1461. 2019.

ARROYO-MORA, J. P. et al. **Assessing the impact of illumination on UAV pushbroom hyperspectral imagery collected under various cloud cover conditions.** *Remote Sensing Of Environment*, v. 258, p. 112396, 2021.

AASEN, H. et al. **Quantitative Remote Sensing at Ultra-High Resolution with UAV Spectroscopy: a review of sensor technology, measurement procedures, and data correction workflows.** *Remote Sensing*, v. 10, n. 7, p. 1091, 2018.

ATTARCHI, S.; GLOAGUEN, R. **Classifying complex mountainous forests with L-band SAR and Landsat data integration: a comparison among different machine learning methods in the hyrcanian forest.** *Remote Sensing*, v. 6, p. 3624–3647, 2014.

AWAIS, M. *et al.* **Assessment of optimal flying height and timing using high-resolution unmanned aerial vehicle images in precision agriculture.** *Int. J. Environ. Sci. Technol.*, v. 19, p. 2703–2720, 2022.

BALUJA, J. et al. **Assessment of vineyard water status variability by thermal and multispectral imagery using an unmanned aerial vehicle (UAV).** *Irrigation Science*, v. 30, n. 6, p. 511–522, 2012.

BANERJEE, B. P.; RAVAL, S.; CULLEN, P. J. **UAV-hyperspectral imaging of spectrally complex environments.** *International Journal Of Remote Sensing.*, v. 41, n. 11, p. 4136-4159, 2020.

BELGIU, M.; DRĂGUȚ, L. **Random Forest in remote sensing: A review of applications and future directions.** *ISPRS J. Photogramm. Remote Sensing*, v. 114, p. 24–31, 2016.

BORGOGNO-MONDINO, E.; LESSIO, A.; GOMARASCA, M.A. **A fast operative method for NDVI uncertainty estimation and its role in vegetation analysis.** *Eur. J. Remote Sensing*, v. 49, p. 137–156. 2016.

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

CAMPBELL, J. B.; WYNNE, R. H. **Introduction to remote sensing.** 5<sup>th</sup> ed. New York: The Guilford Press. 2011.

CAMPBELL, J.B. **Introduction to Remote Sensing**, 5th Edition. Guilford Press, 2012.

CAO, H. et al. **Comparing, validating and improving the performance of reflectance obtention method for UAV-Remote sensing**. International Journal Of Applied Earth Observation And Geoinformation, v. 102, p. 102391, 2021.

CHATURVEDI, V.; VRIES, W. T. de. **Machine Learning Algorithms for Urban Land Use Planning**: a review. Urban Science, v. 5, n. 3, p. 68. 2021.

CHAVEZ Jr, P. S. **Image-Based Atmospheric Corrections**. Revisited and Improved. Photogrammetric Engineering and Remote Sensing, v. 62, n. 9. p. 1025-1036, 1996.

CHEN, G. *et al.* A multiscale geographic object-based image analysis to estimate lidar-measured forest canopy height using Quickbird imagery. **International Journal of Geographical Information Science**, v. 25, p. 37–41, 2012.

CHEN, S. et al. **Urbanization effect on precipitation over the Pearl River Delta based on CMORPH data**. Advances in Climate Change Research Research. v. 6, n. 1 p. 16 – 22, 2015.

CHRISTOVAM, L. E. et al. **Land use and land cover classification using hyperspectral imagery: evaluating the performance of spectral angle mapper, support vector machine and random forest**. The International Archives Of The Photogrammetry, Remote Sensing And Spatial Information Sciences, v. 2, n. 13, p. 1841-1847, 2019.

CHUVIECO, E. **Fundamentals of Satellite Remote Sensing**. An Environmental Approach. (2nd ed.). Boca Raton, FL: CRC Press. 2016.

DENG, S. et al. **Comparison of tree species classifications at the individual tree level by combining ALS data and RGB images using different algorithms**. Remote Sensing, v. 8, n. 12, p. 1034, 2016.

DRONOVA, I. et al. **A review of unoccupied aerial vehicle use in wetland applications: emerging opportunities in approach, technology, and data**. Drones, v. 5, n. 2, 2021.

ELACHI, C.; ZYL, J. J. van. **Introduction of the Physics and Techniques of Remote Sensing**. Hoboken: John Wiley & Sons. 2021.

ELAMIN, A.; EL-RABBANY, A. **UAV-Based Multi-Sensor Data Fusion for Urban Land Cover Mapping Using a Deep Convolutional Neural Network**. Remote Sensing, v. 14, n. 17, p. 4298. 2022.

FASSNACHT, F.E. et al. **Comparison of feature reduction algorithms for classifying tree species with hyperspectral data on three central European test sites**. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, v. 7, n. 6, p. 2547–2561, 2014.

- FENG, Q.; LIU, J.; GONG, J. **UAV Remote Sensing for Urban Vegetation Mapping Using Random Forest and Texture Analysis**. *Remote Sensing*, v. 7, n. 1, 2015.
- FLORES-DE-SANTIAGO, F. et al. **Assessing the effect of flight altitude and overlap on orthoimage generation for UAV estimates of coastal wetlands**. *J Coast Conservation*, v. 24, n. 35, 2020.
- FOODY, G.M.; MATHUR, A. **A relative evaluation of multiclass image classification by support vector machines**. *IEEE Trans. Geosci. Remote Sens*, v. 42, p. 1335–1343, 2004.
- FRASER, B. T; CONGALTON, R. G. **Issues in Unmanned Aerial Systems (UAS) Data Collection of Complex Forest Environment**. *Remote Sensing*, v. 10, n. 908, 2018.
- GITELSON, A.; MERZLYAK, M.N. **Spectral reflectance changes associated with autumn senescence of *A. hippocastanum* L. and *A. platanoides* L. Leaves. Spectral features and relation to chlorophyll estimation**. *Journal of Plant Physiology*, v. 143, p. 286. 1994.
- GITELSON, A.A. et al. **Novel algorithms for remote estimation of vegetation fraction**. *Remote Sens. Environ.* v. 80, p. 76–87. 2002.
- GUO, L. et al. **Relevance of airborne lidar and multispectral image data for urban scene classification using Random Forests**. *ISPRS J. Photogramm. Remote Sensing*, v. 66, p. 56–66, 2011.
- GUO, Q. et al. **Urban Tree Classification Based on Object-Oriented Approach and Random Forest Algorithm Using Unmanned Aerial Vehicle (UAV) Multispectral Imagery**. *Remote Sensing*, v. 14, n. 16, p. 3885, 2022.
- HARALICK, R. M. et al. **Textural features for image classification**. *IEEE Transactions on Systems, Man, and Cybernetics*, v. 3, p. 610–621, 1973.
- HARTLING, S. et al. **Urban tree species classification using a WorldView-2/3 and LiDAR data fusion approach and deep learning**, *Sensors*, v. 19, n. 6, p. 1284, 2019.
- HASHIMOTO, N. et al. **Simulation of Reflectance and Vegetation Indices for Unmanned Aerial Vehicle (UAV) Monitoring of Paddy Fields**. *Remote Sensing*. v. 11, n. 18, p. 2119. 2019.
- HATFIELD, J. L. et al. **Application of spectral remote sensing for agronomic decisions**. *A Supplement to Agronomy Journal*, p. 117-131, 2008.
- HONKAVAARA, E. et al. **Influence of solar elevation in radiometric and geometric performance of multispectral photogrammetry**. *Isprs Journal of Photogrammetry and Remote Sensing*, v. 67, p. 13-26, 2012.
- HUANG, C.; DAVIS, L.; TOWNSHEND, J. **An assessment of support vector machines for land cover classification**. *Int. J. Remote Sens*, v. 23, p. 725–749. 2002.

JENSEN, J. R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. 2 ed. São José dos Campos, SP: Parênteses, 2009.

KALANTAR, B. et al. **Framework for Multiple Moving Objects Detection in Aerial Videos**. Spatial Modeling in GIS and R for Earth and Environmental Sciences; Elsevier: Amsterdam, The Netherlands, 2019; pp. 573–588.

KEYPORT, R. N. et al. **A comparative analysis of pixel- and object-based detection of landslides from very high-resolution images**. International Journal Of Applied Earth Observation And Geoinformation. v. 64, p. 1-11, fev. 2018.

LALIBERTE, A. S.; RANGO, A. **Texture and Scale in Object-Based Analysis of Subdecimeter Resolution Unmanned Aerial Vehicle (UAV) Imagery**. IEEE Transactions on Geoscience and Remote Sensing. v. 47. n.3. p. 761–770. 2009.

LECHNER, A.M. *et al.* **Upland Swamps Using Object-Based Classification Methods and Hyper-Spatial Resolution Imagery Derived from An Unmanned Aerial Vehicle**. Annals of the Photogrammetry. Remote Sensing and Spatial Information Sciences, v. 6, p. 101-106, 2012.

LIAW, A; M. WIENER. **Classification and Regression by randomForest**. R News, n. 2, p. 18-22. 2002.

LIN, C. et al. **Classification of tree species in overstorey canopy of subtropical forest using QuickBird images**. PLOS ONE, v. 10, n. 5. 2015.

LIU, S. et al. **A. Integration of Convolutional Neural Networks and Object-Based Post-Classification Refinement for Land Use and Land Cover Mapping with Optical and SAR Data**. Remote Sensing, v. 11, n. 6, p. 690, 2019.

LIU, S. et al. **A novel fire index-based burned area change detection approach using Landsat-8 OLI data**. European Journal of Remote Sensing, v. 53, n. 1, p. 104–112, 2020.

LIU, W.; F. YAMAZAKI. **Object-Based Shadow Extraction and Correction of HighResolution Optical Satellite Images**. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing. v. 5, n. 4, p. 1296–1302. 2012.

LORENA, A. C.; CARVALHO, A. C. P. L. F. **Uma introdução às support vectors machines - tutorial**. Revista de Informática Teórica e Aplicada. v. 14, n. 2, p. 43-67, 2007.

LOUHAICHI, M.; BORMAN, M. M.; JOHNSON, D. E. **Spatially located platform and aerial photography for documentation of grazing impacts on wheat**. Geocarto International. Taylor & Francis, v. 16, n. 1, p. 65–70, 2001.

LU, D. et al. **Land use/cover classification in the brazilian Amazon using satellite images**. Brazilian Journal of Agricultural Research, v. 47, p. 1185–1208, 2012.

LUCA, G. de. Et al. **Object-Based Land Cover Classification of Cork Oak Woodlands using UAV Imagery and Orfeo ToolBox**. *Remote Sensing*, v. 11, n. 10, p. 1238, 2019.

MATESE, A. et al. **Intercomparison of UAV, Aircraft and Satellite Remote Sensing Platforms for Precision Viticulture**. *Remote Sensing*, v.7, p. 2971–2990, 2015.

MAXWELL, A. et al. **Assessing machine-learning algorithms and image-and lidar-derived variables for GEOBIA classification of mining and mine reclamation**. *Int. J. Remote Sens.* v. 36, p. 954–978, 2015.

MILAS, A. S. et al. **Different colours of shadows: classification of uav images**. *International Journal Of Remote Sensing*, v. 38, n. 8-10, p. 3084-3100. 2017.

MOREIRA, M. A. **Fundamentos do sensoriamento remoto e metodologias de aplicação**. São José dos Campos: Instituto Nacional de Pesquisas Espaciais, 2001.

MOUSTAFA, M. Z. et al. **A BI-objective Model for SVM With an Interactive Procedure to Identify the Best Compromise Solution**. *International Journal of Artificial Intelligence & Applications*. v. 11. n. 2. p. 49-59. 2020.

MYINT, S. W. et al. **Per-pixel vs. object-based classification of urban land cover extraction using high spatial resolution imagery**. *Remote Sensing Of Environment*, v. 115, n. 5, p. 1145-1161, 2011.

NGUYEN, H. T. T.; DOAN, T. M.; RADELOFF, V. **Applying random forest classification to map land use/land cover using landsat 8 oli**. *Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci*, 2018.

NOI, P. T.; KAPPAS, M. **Comparison of Random Forest k-Nearest Neighbor e Support Vector Machine Classifiers for Land Cover Classification Using Sentinel-2 Imagery**. *Sensors*, v. 18, n. 1. 2018.

NOVO, E. M. L. M. **Sensoriamento remoto: princípios e aplicações**. 2 ed. São Paulo: Edgar Blucher, 1992.

NOVO, E. M. L. M. **Sensoriamento remoto: princípios e aplicações**. 4.ed. São Paulo: Edgard Blücher, 2011.

PÁDUA, L. et al. **UAS, sensors, and data processing in agroforestry: a review towards practical applications**. *International Journal of Remote Sensing*, v. 38, n. 8–10, p. 2349–2391, 2017.

PARK, G. et al. **Analyzing Impact of Types of UAV-Derived Images on the Object-Based Classification of Land Cover in an Urban Area**. *Drones*, v. 6. n. 3. p. 71. 2022.



PONS, X.; PADRÓ, J. -C. **An Empirical Approach on Shadow Reduction of UAV Imagery in Forests.** *IGARSS 2019 - 2019 IEEE International Geoscience and Remote Sensing Symposium.* 2019.

PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, T. M. **Sensoriamento remoto da vegetação.** 2. ed. São Paulo: Oficina de Textos, 2012.

QI, J. et al. **A modified soil adjusted vegetation index.** *Remote Sensing Of Environment*, v. 48, n. 2, p. 119-126, maio 1994.

QIAN, Y.; ZHOU, W.; YAN, J.; LI, W.; HAN, L. **Comparing machine learning classifiers for object-based land cover classification using very high-resolution imagery.** *Remote Sensing*, v. 7, p. 153–168. 2015.

RODRIGEZ, M. P. R. et al. **Ajuste e desempenho dos índices de perigo de incêndios Nesterov, FMA e FMA+ na empresa florestal Macurije Cuba.** *Revista Floresta.* Curitiba, v. 42, n. 4, p. 651-600, 2012.

RONDEAUX, G.; STEVEN, M.; BARET, F. **Optimization of soil-adjusted vegetation indices.** *Remote Sens. Environ*, v. 55. p. 95–107. 1996.

ROUSE, J. et al. **Monitoring vegetation systems in the Great Plains with ERTS.** In: *ERTS SYMPOSIUM*, 3., 1973. Proceedings... 1973. p.309-317. (NASA SP-351).

RUWAIMANA, M. et al. **The advantages of using drones over space-borne imagery in the mapping of mangrove forests.** *PLOS ONE*, v. 13, n. 7, 2018.

SAHITHI, V. S.; KRISHNA, I.; V M.; GIRIDHAR, M. V. S. S. **Analysing the Sensitivity of SVM Kernels on Hyperspectral Imagery for Land Use Land Cover Classification.** *Journal Of Image Processing And Artificial Intelligence*, v. 8, n. 2, p. 15-23. 2022.

SINGH, K. K.; FRAZIER, A. E. **A meta-analysis and review of unmanned aircraft system (UAS) imagery for terrestrial applications.** *International Journal Of Remote Sensing*, v. 39, n. 15, p. 5078-5098, 2018.

STEINWART, I.; CHRISTMANN, A. **Support vector machines.** New York: Springer, 2008.

SUN, T. et al. **GIS-based mineral prospectivity mapping using machine learning methods: a case study from Tongling ore district, eastern china.** *Ore Geology Reviews*, v. 109, p. 26-49, jun. 2019.

SWAYZE, N. C. et al. **Influence of UAS Flight Altitude and Speed on Aboveground Biomass Prediction.** *Remote Sensing*. v. 14, n. 9, p. 1989, 2022.

TORRESAN, C. et al. **Forestry applications of UAVs in Europe: A review.** *Int. J. Remote Sensing*, v.38, 2427–2447, 2017.

TSO, B.; MATHER, P. **Classification Methods for Remotely Sensed Data**. CRC Press: Boca Raton, FL, USA. p. 367. 2009.

VAN DER WERFF, H. M. A.; VAN DER MEER, F. D. **Shape-based classification of spectrally identical objects**. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 63, n. 2, p. 251–258. 2008.

VAN IERSEL, W. et al. **Monitoring height and greenness of non-woody floodplain vegetation with UAV time series**. *ISPRS J. Photogramm. Remote Sens*, v. 141, p. 112–123, 2018.

VERSTRAETE, M.M.; PINTY, B.; MYNENI, R.B. **Potential and limitations of information extraction on the terrestrial biosphere from satellite remote sensing**. *Remote Sens. Environ*, v. 58, p. 201–214, 1996.

WANG, C.; MYINT, S. W. **A Simplified Empirical Line Method of Radiometric Calibration for Small Unmanned Aircraft Systems-Based Remote Sensing**. *IEEE JSTARS*, v. 8. n. 5. p. 1876-1885, 2015.

WANG, S. et al. **Unmanned Aerial System multispectral mapping for low and variable solar irradiance conditions: potential of tensor decomposition**. *Isprs Journal of Photogrammetry And Remote Sensing*, v. 155, p. 58-71. 2019.

WASKE, B. et al. **Sensitivity of support vector machines to random feature selection in classification of hyperspectral data**. *IEEE Trans. Geosci. Remote Sens*, v. 48, p. 2880–2889, 2010.

WULDER, M. A. et al. **Land cover 2.0**. *International Journal of Remote Sensing*, v. 39, n. 12, p. 4254-4284, 2018.

XIANG, H., TIAN, L. **Development of a low-cost agricultural remote sensing system based on an autonomous unmanned aerial vehicle (UAV)**. *Biosystems Engineering*, v. 108, n. 2, p. 174–190, 2011.

YAN, W. Y.; SHAKER, A.; EL-ASHMAWY, N. **Urban land cover classification using airborne LiDAR data: a review**. *Remote Sensing of Environment*, v. 158. p. 295-310.2015.

YANG, X. **Parameterizing support vector machines for land cover classification**. *Photogramm. Eng. Remote Sens*, v. 77, p. 27–37. 2011.

YAO, H.; QIN, R.; CHEN, X.J.R.S. **Unmanned aerial vehicle for remote sensing applications—A review**. *Remote Sensing*. v. 11, p. 1443, 2019.

YOO, S.H. et al. **Automatic generation of land cover map using residual U-Net**. *KSCE J. Civil Environ. Eng. Res*, v. 40, 535–546. 2020.

ZHANG, J. et al. **Intra- and inter-class spectral variability of tropical tree species at La Selva, Costa Rica: implications for species identification using HYDICE imagery.** *Remote Sens. Environ.* 105, 129– 141, 2006.

ZHANG, L.; ZHANG, L.; DU, B. **Deep Learning for Remote Sensing Data: A Technical Tutorial on the State of the Art.** *IEEE Geoscience and Remote Sensing Magazine*, v. 4, n. 2, p. 22-40. 2016.

ZHU, L. *et al.* A Review: Remote Sensing Sensors. *In: RUSTAMO, R. B.; HASANOVA, S.; ZEYNALOVA, M. H. Multi-purposeful Application of Geospatial Data.* IntechOpen, p. 19-43, 2018.

ZYLSHAL, *et al.* **A support vector machine object-based image analysis approach on urban green space extraction using Pleiades-1A imagery.** *Modeling Earth Systems and Environment*, v. 2, n. 54, p. 1-12, 2016.

## APÊNDICE

**APÊNDICE 1** - Métricas de acurácia dos classificadores e esquemas diferentes para a classificação da imagem adquirida a 120 m de altitude e iluminação direta.

<b>Esquema</b>	<b>Modelo</b>	<b>Precisão Geral</b>	<b>F1-Score</b>	<b>Coefficiente Kappa</b>
S1	Random Forest	0.94	0.94	0.92
S1	Support Vector Machine	0.82	0.79	0.78
S2	Random Forest	0.93	0.93	0.92
S2	Support Vector Machine	0.86	0.86	0.83
S3	Random Forest	0.95	0.94	0.93
S3	Support Vector Machine	0.88	0.87	0.85
S4	Random Forest	0.95	0.95	0.93
S4	Support Vector Machine	0.72	0.73	0.66
S5	Random Forest	0.95	0.95	0.94
S5	Support Vector Machine	0.90	0.90	0.88
S6	Random Forest	0.95	0.95	0.93
S6	Support Vector Machine	0.76	0.77	0.71
S7	Random Forest	0.95	0.95	0.94
S7	Support Vector Machine	0.76	0.77	0.71
S8	Random Forest	0.96	0.96	0.95
S8	Support Vector Machine	0.80	0.81	0.76

**APÊNDICE 2** - Métricas de acurácia dos classificadores e esquemas diferentes para a classificação da imagem adquirida a 120 m de altitude e iluminação difusa.

<b>Esquema</b>	<b>Modelo</b>	<b>Precisão Geral</b>	<b>F1-Score</b>	<b>Coefficiente Kappa</b>
S1	Random Forest	0.93	0.93	0.92
S1	Support Vector Machine	0.82	0.79	0.78
S2	Random Forest	0.94	0.94	0.92
S2	Support Vector Machine	0.85	0.85	0.82
S3	Random Forest	0.95	0.95	0.94
S3	Support Vector Machine	0.87	0.85	0.84
S4	Random Forest	0.96	0.95	0.95
S4	Support Vector Machine	0.73	0.74	0.67
S5	Random Forest	0.96	0.95	0.95
S5	Support Vector Machine	0.91	0.91	0.89
S6	Random Forest	0.96	0.95	0.95
S6	Support Vector Machine	0.75	0.76	0.70
S7	Random Forest	0.96	0.96	0.95
S7	Support Vector Machine	0.76	0.76	0.70
S8	Random Forest	0.97	0.96	0.96
S8	Support Vector Machine	0.78	0.79	0.74

**APÊNDICE 3** - Métricas de acurácia dos classificadores e esquemas diferentes para a classificação da imagem adquirida a 150 m de altitude e iluminação direta.

<b>Esquema</b>	<b>Modelo</b>	<b>Precisão Geral</b>	<b>F1-Score</b>	<b>Coefficiente Kappa</b>
S1	Random Forest	0.93	0.93	0.91
S1	Support Vector Machine	0.82	0.79	0.78
S2	Random Forest	0.94	0.94	0.92
S2	Support Vector Machine	0.86	0.86	0.83
S3	Random Forest	0.94	0.94	0.93
S3	Support Vector Machine	0.90	0.90	0.88
S4	Random Forest	0.96	0.95	0.95
S4	Support Vector Machine	0.72	0.72	0.65
S5	Random Forest	0.94	0.94	0.93
S5	Support Vector Machine	0.88	0.88	0.86
S6	Random Forest	0.95	0.94	0.93
S6	Support Vector Machine	0.76	0.77	0.71
S7	Random Forest	0.96	0.95	0.95
S7	Support Vector Machine	0.76	0.77	0.71
S8	Random Forest	0.95	0.95	0.94
S8	Support Vector Machine	0.79	0.80	0.75

**APÊNDICE 4** - Métricas de acurácia dos classificadores e esquemas diferentes para a classificação da imagem adquirida a 150 m de altitude e iluminação direta.

<b>Esquema</b>	<b>Modelo</b>	<b>Precisão Geral</b>	<b>F1-Score</b>	<b>Coefficiente Kappa</b>
S1	Random Forest	0.93	0.93	0.91
S1	Support Vector Machine	0.83	0.79	0.79
S2	Random Forest	0.94	0.94	0.93
S2	Support Vector Machine	0.86	0.86	0.83
S3	Random Forest	0.94	0.93	0.92
S3	Support Vector Machine	0.90	0.90	0.88
S4	Random Forest	0.96	0.96	0.95
S4	Support Vector Machine	0.74	0.74	0.68
S5	Random Forest	0.96	0.96	0.95
S5	Support Vector Machine	0.91	0.91	0.89
S6	Random Forest	0.97	0.97	0.96
S6	Support Vector Machine	0.76	0.77	0.71
S7	Random Forest	0.96	0.96	0.95
S7	Support Vector Machine	0.76	0.77	0.71
S8	Random Forest	0.95	0.95	0.94
S8	Support Vector Machine	0.80	0.80	0.75

**APÊNDICE 5 - Matrizes de coocorrência para a classificação da imagem adquirida a 120 m de altitude e iluminação direta**

Classes - RF	Verdade de campo							Total	UA
	Construção	Asfalto	Gramma	Árvore	Solo	Veículos	Calçada		
<b>Construção</b>	13	0	0	0	0	0	1	14	92.86
<b>Asfalto</b>	0	21	0	0	0	2	7	30	70.00
<b>Gramma</b>	0	0	27	18	0	0	0	45	60.00
<b>Árvore</b>	2	0	2	36	0	0	0	40	90.00
<b>Solo</b>	1	0	0	0	30	0	0	31	96.77
<b>Veículos</b>	0	0	0	0	0	13	1	14	92.86
<b>Calçada</b>	1	1	0	2	0	1	21	26	80.77
<b>Total</b>	17	22	29	56	30	16	30	200	
<b>PA</b>	76.47	95.45	93.10	64.29	100.00	81.25	70.00		
<b>OA</b>	80.50				<b>Kappa</b>	0.77			

Classes - SVM	Verdade campo							Total	UA
	Construção	Asfalto	Gramma	Árvore	Solo	Veículos	Calçada		
<b>Construção</b>	14	0	0	0	0	0	0	14	100.00
<b>Asfalto</b>	1	17	1	0	1	0	10	30	56.67
<b>Gramma</b>	0	1	30	14	0	0	0	45	66.67
<b>Árvore</b>	4	0	1	35	0	0	0	40	87.50
<b>Solo</b>	2	1	0	1	26	0	1	31	83.87
<b>Veículos</b>	1	0	0	0	0	13	0	14	92.86
<b>Calçada</b>	3	4	0	1	0	0	18	26	69.23
<b>Total</b>	25	23	32	51	27	13	29	200	
<b>PA</b>	56.00	73.91	93.75	68.63	96.30	100.00	62.07		
<b>OA</b>	76.50				<b>Kappa</b>		0.72		

**APÊNDICE 6 -** Matrizes de coocorrência para a classificação da imagem adquirida a 120 m de altitude e iluminação difusa.

Classes - RF	Verdade de campo							Total	UA
	Construção	Asfalto	Gramma	Árvore	Solo	Veículos	Calçada		
<b>Construção</b>	13	0	0	0	0	0	1	14	92.86
<b>Asfalto</b>	0	20	0	0	0	2	8	30	66.67
<b>Gramma</b>	0	0	30	15	0	0	0	45	66.67
<b>Árvore</b>	2	0	2	36	0	0	0	40	90.00
<b>Solo</b>	1	0	0	0	30	0	0	31	96.77
<b>Veículos</b>	0	0	0	0	0	12	2	14	85.71
<b>Calçada</b>	1	1	0	1	0	1	22	26	84.62
<b>Total</b>	17	21	32	52	30	15	33	200	
<b>PA</b>	76.47	95.24	93.75	69.23	100.00	80.00	66.67		
<b>AO</b>	81.50				<b>Kappa</b>	0.78			

Classes - SVM	Verdade de campo							Total	UA
	Construção	Asfalto	Gramma	Árvore	Solo	Veículos	Calçada		
<b>Construção</b>	14	0	0	0	0	0	0	14	100.00
<b>Asfalto</b>	1	17	1	0	0	1	10	30	56.67
<b>Gramma</b>	1	0	29	15	0	0	0	45	64.44
<b>Árvore</b>	4	0	1	35	0	0	0	40	87.50
<b>Solo</b>	2	1	1	0	25	0	2	31	80.65
<b>Veículos</b>	1	0	0	0	0	13	0	14	92.86
<b>Calçada</b>	3	5	0	1	0	0	17	26	65.38
<b>Total</b>	26	23	32	51	25	14	29	200	
<b>PA</b>	53.85	73.91	90.63	68.63	100.00	92.86	58.62		
<b>OA</b>	75.00				<b>Kappa</b>	0.70			

**APÊNDICE 7 - Matrizes de coocorrência para a classificação da imagem adquirida a 150 m de altitude e iluminação direta.**

Classes - RF	Verdade de campo							Total	UA
	Construção	Asfalto	Gramma	Árvore	Solo	Veículos	Calçada		
<b>Construção</b>	13	0	0	0	0	0	1	14	92.86
<b>Asfalto</b>	1	20	0	0	0	2	7	30	66.67
<b>Gramma</b>	0	0	25	20	0	0	0	45	55.56
<b>Árvore</b>	3	0	1	36	0	0	0	40	90.00
<b>Solo</b>	1	0	0	0	30	0	0	31	96.77
<b>Veículos</b>	2	0	0	1	0	10	1	14	71.43
<b>Calçada</b>	3	1	0	0	0		22	26	84.62
<b>Total</b>	23	21	26	57	30	12	31	200	
<b>PA</b>	56.52	95.24	96.15	63.16	100.00	83.33	70.97		
<b>OA</b>	78.00				<b>Kappa</b>	0.74			

Classes - SVM	Verdade de campo							Total	UA
	Construção	Asfalto	Gramma	Árvore	Solo	Veículos	Calçada		
<b>Construção</b>	12	0	0	0	1	0	1	14	85.71
<b>Asfalto</b>	0	18	0	0	0	3	9	30	60.00
<b>Gramma</b>	1	0	8	36	0	0	0	45	17.78
<b>Árvore</b>	3	0	3	34	0	0	0	40	85.00
<b>Solo</b>	1	1	0	0	27	0	2	31	87.10
<b>Veículos</b>	0	0	0	1	0	12	1	14	85.71
<b>Calçada</b>	1	3		1	0	0	21	26	80.77
<b>Total</b>	18	22	11	72	28	15	34	200	
<b>PA</b>	66.67	81.82	72.73	47.22	96.43	80.00	61.76		
<b>OA</b>	66.00				<b>Kappa</b>	0.60			



**APÊNDICE 8** - Matrizes de coocorrência para a classificação da imagem adquirida a 150 m de altitude e iluminação difusa.

Classes - RF	Verdade de campo							Total	UA
	Construção	Asfalto	Gramma	Árvore	Solo	Veículos	Calçada		
<b>Construção</b>	13	0	0	0	0	0	1	14	92.86
<b>Asfalto</b>	0	20	0	0	0	1	9	30	66.67
<b>Gramma</b>	0	0	31	14	0	0	0	45	68.89
<b>Árvore</b>	2	0	0	38	0	0	0	40	95.00
<b>Solo</b>	1	0	0	0	29	0	1	31	93.55
<b>Veículos</b>	0	0	0	0	0	12	2	14	85.71
<b>Calçada</b>	3	1	0	0	0	1	21	26	80.77
<b>Total</b>	19	21	31	52	29	14	34	200	
<b>PA</b>	68.42	95.24	100.00	73.08	100.00	85.71	61.76		
<b>AO</b>	82.00				<b>Kappa</b>	0.79			

Classes - SVM	Verdade de campo							Total	UA
	Construção	Asfalto	Gramma	Árvore	Solo	Veículos	Calçada		
<b>Construção</b>	14	0	0	0	0	0	0	14	100.00
<b>Asfalto</b>	1	17	1	0	1	0	10	30	56.67
<b>Gramma</b>	0	1	32	12	0	0	0	45	71.11
<b>Árvore</b>	4	0	1	35	0	0	0	40	87.50
<b>Solo</b>	1	1	2	0	25	0	2	31	80.65
<b>Veículos</b>	0	0	0	0	0	13	1	14	92.86
<b>Calçada</b>	2	5	0	1	0	1	17	26	65.38
<b>Total</b>	22	24	36	48	26	14	30	200	
<b>PA</b>	63.64	70.83	88.89	72.92	96.15	92.86	56.67		
<b>AO</b>	76.50				<b>Kappa</b>	0.72			